

SVEUČILIŠTE U RIJECI
POMORSKI FAKULTET U RIJECI

Jasmin Ćelić

**MODEL KOOPERATIVNOGA PRISTUPA
U SUSTAVIMA UPUĆIVANJA VOZILA NA
PARKIRANJE**

DOKTORSKI RAD

Rijeka, 2015.

SVEUČILIŠTE U RIJECI
POMORSKI FAKULTET U RIJECI

Jasmin Ćelić

**MODEL KOOPERATIVNOGA PRISTUPA
U SUSTAVIMA UPUĆIVANJA VOZILA NA
PARKIRANJE**

DOKTORSKI RAD

Mentor: prof. dr. sc. Vinko Tomas

Rijeka, 2015.

UNIVERSITY OF RIJEKA
FACULTY OF MARITIME STUDIES IN RIJEKA

Jasmin Ćelić

**MODEL OF COOPERATIVE APPROACH
TO PARKING GUIDANCE SYSTEMS**

DOCTORAL THESIS

Rijeka, 2015

Mentor rada: prof. dr. sc. Vinko Tomas

Doktorski rad obranjen je 21.7.2015. na Pomorskom fakultetu Sveučilišta u Rijeci, pred povjerenstvom:

1. Prof. dr. sc. Dragan Čišić, predsjednik
(Pomorski fakultet u Rijeci)
2. Prof. dr. sc. Vinko Tomas, mentor, član
(Pomorski fakultet u Rijeci)
3. Izv. prof. dr. sc. Sadko Mandžuka, član
(Fakultet prometnih znanosti Sveučilišta u Zagrebu)
4. Doc. dr. sc. Irena Jurdana, član
(Pomorski fakultet u Rijeci)
5. Doc. dr. sc. Siniša Vilke, član
(Pomorski fakultet u Rijeci)

Doktorski rad je izrađen u sklopu projekta 'Informacijsko-komunikacijske tehnologije u inteligentnim prometnim sustavima' (2014-2015, voditelj prof. dr. sc. Vinko Tomas, Pomorski fakultet Sveučilišta u Rijeci) i projekta 'Intelligent Cooperative Sensing for Improved Traffic Efficiency' (FP7-317671, 2012-2015, voditelj izv. prof. dr. sc. Sadko Mandžuka, Fakultet prometnih znanosti Sveučilišta u Zagrebu).

SAŽETAK

Trend rasta i migracije stanovništva u gradska središta te kontinuirano povećanje broja motornih vozila uzrokuju prometne gužve i zagušenja u većini velikih svjetskih gradova. Jedan od prepoznatih uzroka navedenog negativnog učinka je kruženje u potrazi za raspoloživim parkirališnim mjestom koji ne samo da doprinosi ukupnoj količini zagušenja u gradskim centrima već utječe na količinu vremena koje vozači bespotrebno provode u vozilu, razinu stresa vozača, količinu emisije štetnih plinova, te indirektno na zdravlje i sigurnost svih živih bića.

U svrhu otklanjanja problema izazvanim kruženjem u potrazi za raspoloživim parkirališnim mjestom, odnosno zagušenjem, provode se različite metode i pristupi. Prije svega su to odgovarajuće strategije i politike koje se donose s ciljem uređenja postojećeg stanja i demotiviranja dijela stanovništva čiji dolazak u gradski centar nije nužan. Drugi su načini, kojima se u ovome radu posvećuje najveća pažnja, inteligentni parkirališni sustavi.

Inteligentni parkirni sustavi se koriste za upućivanje vozača na raspoloživa parkirališna mjesta i pružanje informacija o njihovim karakteristikama. Redovito se koriste i za rezervaciju i naplatu parkiranja, no u najvećem broju slučajeva bili su vezani isključivo za zatvorena parkirališta i garaže. Tehnološkim napretkom i razvojem inteligentnih osjetila postalo je moguće kontrolirati i ulična parkirališna mjesta što se u ovome radu posebno ističe.

U radu je analiziran klasičan model traženja raspoloživog parkirališnog mjesta, a zatim je predložen napredni model upućivanja na raspoloživa parkirališna mjesta upotrebom kooperativnog pristupa. Izrađen je simulacijski model predloženog naprednog sustava i ispitani su pokazatelji uspješnosti za četiri različita scenarija u slučaju s i bez zagušenja prometnog toka. Provedena simulacija pokazala je sve prednosti ovakvog sustava u odnosu na klasičan pristup i istaknuti su vodeći čimbenici njegove učinkovitosti.

Ključne riječi:

Inteligentni transportni sustavi, kooperativan pristup, napredni sustavi za informiranje putnika, inteligentni parkirni sustavi, sustavi za upućivanje i navigaciju, traženje rute, parkiranje, parkirališta.

SUMMARY

The growth trend and the trend of population migration into city centers, as well as the continuous increase in the number of motor vehicles cause traffic jams and congestions in most major cities in the world. One of the identified factors of the above mentioned negative effect is the circling in search of available parking space, which not only contributes to the total amount of congestion in city centers, but also affects the amount of time that drivers spend unnecessarily in vehicle, the stress level of drivers, the amount of emissions, and, indirectly, the health and safety of living beings.

In order to eliminate the problems caused by the circling in search of available parking space, i.e. by the congestion, the different methods and approaches are implemented. First of all, these are the appropriate strategies and policies that are made in order to regulate the existing situation and to demotivate the arrival of part of the population in the city center, which does not represent a necessity. Another way to eliminate the above problem, which is the most emphasized in this paper, is represented by the intelligent parking systems.

Intelligent parking systems are used to guide the driver to the available parking space and to provide the information on the characteristics of the same. Regularly they are also used for parking reservation and payment, but in most cases they were related exclusively to closed parking lots and garages. With the technological progress and the development of intelligent sensors it has become possible to even control street parking spaces, which is especially emphasized in this paper.

Furthermore, the classic model of search of available parking spaces is analyzed, and then the advanced model of guidance to available parking spaces using a cooperative approach is proposed. The simulation model of the proposed advanced system is developed and indicators of effectiveness for four different scenarios in the cases with and without traffic congestion are examined. The simulation analysis presents the advantages of this system compared to the classical approach and main factors of its effectiveness are highlighted.

Keywords:

Intelligent Transportation Systems, Cooperative Approach, Advanced Transport Information Systems, Intelligent Parking Systems, Guidance and Navigation Systems, Routes Searching, Parking, Parking Lots.

Sadržaj


SAŽETAK.....	vi
SUMMARY.....	vii
Sadržaj.....	viii
1. UVOD.....	1
1.1. Problem, predmet i objekt istraživanja.....	8
1.2. Znanstvena hipoteza i pomoćne hipoteze.....	9
1.3. Svrha i ciljevi istraživanja.....	10
1.4. Pregled dosadašnjih istraživanja	10
1.5. Znanstvene metode.....	13
1.6. Struktura rada	14
2. PARKIRANJE I PARKIRALIŠTA	16
2.1. Obilježja parkiranja.....	17
2.2. Upravljanje parkiranjem.....	21
2.3. Sustavi za informiranje i upućivanje na parkirališna mjesta.....	25
2.3.1. PGI sustavi u gradskim središtima.....	26
2.3.2. PGI sustavi u sklopu velikih parkirališta.....	27
2.3.3. Moderni PGI sustavi	28
3. NAPREDNI SUSTAVI ZA INFORMIRANJE PUTNIKA.....	38
3.1. Napredna osjetila u cestovnom prometu	40
3.1.1. Induktivne petlje.....	41
3.1.2. Magnetska osjetila.....	41
3.1.3. Radarska osjetila.....	42
3.1.4. Infracrvena osjetila	43
3.1.5. Ultrazvučna osjetila	43
3.1.6. Akustična osjetila.....	44
3.1.7. Videoprocessori.....	45
3.2. Napredne tehnologije za lociranje vozila i navigaciju.....	46
3.2.1. Pozicijski sustavi.....	46
3.2.2. Tehnologije za prikaz i pružanje informacija	49
3.2.2.1. Znakovi s dinamičkim sadržajem	49

3.2.2.2. Radiosustavi.....	52
3.2.2.3. Ostale metode informiranja putnika	54
3.3. Sustavi za navigaciju i upućivanje vozila.....	54
4. KOOPERATIVNI INTELIGENTNI TRANSPORTNI SUSTAVI U CESTOVNOM PROMETU	57
4.1. C-ITS arhitektura.....	59
4.1.1. Komponente sustava.....	61
4.1.1.1. Aplikacijska jedinica	62
4.1.1.2. Jedinica u vozilu.....	62
4.1.1.3. Jedinica u cestovnoj infrastrukturi.....	62
4.1.2. Tehnički preduvjeti i ograničenja.....	63
4.2. Komunikacija u kooperativnim sustavima	65
4.2.1. Norme i akronimi.....	66
4.2.2. Distribuirano upravljanje zagušenjima u komunikaciji.....	68
4.3. ICSI arhitektura sustava	69
4.3.1. Domenski model	72
4.3.2. Funkcionalni model	74
4.3.3. Komunikacijski model	77
4.3.4. Informacijski model.....	78
4.3.5. Sigurnosni model.....	79
5. MODELI IZBORA RUTE	80
5.1. Najkraći put	81
5.2. Korisnička ravnoteža.....	81
5.3. Stohastička korisnička ravnoteža	83
5.4. Metoda označavanja	84
5.5. Algoritam K različitih putova.....	86
5.6. Uklanjanje prometnih dionica	87
5.7. Metoda otežavajućih čimbenika	87
5.8. Metoda grananja.....	88
5.9. Simulacijski pristup	88
5.10. C-Logit	89
5.11. Logit veličine puta.....	91
5.12. Poprečno ugniježđeni Logit	92
5.13. Probit i Logit jezgra	94
5.14. Implicitna raspoloživost / perceptivni Logit	95

5.15. Generiranje skupa izbora i izbor rute	97
6. NAPREDNI MODEL UPUĆIVANJA VOZILA NA RASPOLOŽIVA PARKIRALIŠNA MJESTA	100
6.1. Struktura sustava cestovnog prometa	100
6.1.1. Modeliranje prometne infrastrukture	100
6.1.2. Modeliranje cestovnog prometa	102
6.1.3. Ponašanje vozača	103
6.1.4. Dodjeljivanje prometa	104
6.2. Klasični model traženja raspoloživog parkirališnog mjesta	107
6.3. Napredni model sustava za upućivanje vozila na raspoloživa parkirališna mjesta s kooperativnim pristupom	109
6.3.1. Opis naprednog modela s kooperativnim pristupom	110
6.3.2. Vrijeme putovanja i ukupni troškovi	112
6.3.3. Traženje i izbor odgovarajuće rute	115
6.3.4. Izbor parkirališnog mjesta	117
7. EVALUACIJA USPJEŠNOSTI NAPREDNOG MODELA ZA UPUĆIVANJE VOZILA	120
7.1. Opis simulacijskog modela	120
7.2. Ispitivanje i ocjena uspješnosti simulacijskog modela	122
7.2.1. Vrijeme putovanja	122
7.2.2. Prijedeni put	129
7.2.3. Ukupni troškovi	130
7.2.4. Emisija štetnih plinova	132
7.3. Diskusija rezultata	134
8. ZAKLJUČAK	137
POPIS KRATICA I AKRONIMA	141
POPIS OZNAKA I SIMBOLA	146
POPIS SLIKA	151
POPIS TABLICA	153
Bibliografija	154
Životopis	164

1. UVOD

Razvoj gradskih središta i sve veći broj vozila na cestama širom svijeta, odnosno vidljivo povećanje potražnje za parkirališnim mjestima u gradskim centrima ozbiljno utječe na kvalitetu prometa. Traženje slobodnog parkirališnog mjesta povećava prometni volumen kojeg postojeći kapacitet prometne mreže nije u mogućnosti na odgovarajući način zadovoljiti.



Slika 1. Povećanje broja putničkih vozila na 1000 stanovnika 1990.-2004. [1]

Svakodnevni život ljudi značajno ovisi o prometu. Stalni porast cestovnog prometa izvor je mnogih ozbiljnih problema u pogledu zagušenja, sigurnosti i utjecaja na okolinu. Zahvati na postojećoj infrastrukturi ili u potpunosti nova infrastruktura, ako ih je uopće moguće realizirati zbog postojećih ograničenja, ne mogu riješiti sve navedene probleme. Stoga se u tu svrhu koriste inovativni pristupi u okviru inteligentnih transportnih sustava koji upotrebom informacijsko-komunikacijskih tehnologija nude odgovarajuća napredna rješenja prometnih problema.

Inteligentni transportni sustavi imaju široku primjenu u različitim transportnim modovima i prometnim segmentima pa se tako, najčešće pod nazivom inteligentni sustavi parkiranja ili pametni parkirni sustavi, mogu pronaći i kao odgovor na probleme koji su posredno ili neposredno uzrokovani parkiranjima. Potražnja za odgovarajućim slobodnim parkirališnim mjestom jedan je od vodećih uzročnika zagušenja u gradskim središtima [2]. Kruženje prometnicama u potrazi za slobodnim parkirališnim mjestom ne povećava ukupno vrijeme

putovanja samo tog vozila već i svih ostalih vozila koja su zbog prouzročenog zagušenja i zastoja morala usporiti ili stati. Time se ukupni negativni učinci ovoga fenomena poput potrošnje goriva, emisije štetnih plinova, proizvodnje buke i ugrožavanja sigurnosti znatno uvećavaju. Jedna od vodećih svjetskih kompanija na području navigacijskih i kartografskih proizvoda objavila je indekse prometnih zagušenja za preko 180 gradova na gotovo svim kontinentima diljem svijeta provodeći mjerenja u različitim dijelovima dana i svim danima u tjednu. Visoka razina prometnih zagušenja koja se može pronaći u glavnim gradovima pojedinih zemalja pokazuje koliko je rasprostranjen i ozbiljan navedeni problem. Naime, zagušenje u Moskvi (Rusija) iznosi čak 74 %. U tablici 1. prikazani su indeksi zagušenja za europske gradove koje najviše pogađa ova pojava.

Tablica 1. 10 prometno najzagušenijih gradova u Europi u 2013. godini [3]

Poredak	Trend	Grad	Država	Razina zagušenja	Vršno jutarnje zagušenje	Vršno poslijepodnevno zagušenje	Autoceste	Ostalo
1.	...	Palermo	Italy	39 %	60 %	64 %	29 %	45 %
2.	↓	Warsaw	Poland	39 %	71 %	75 %	37 %	41 %
3.	↓	Rome	Italy	37 %	71 %	64 %	26 %	41 %
4.	↓	Dublin	Ireland	35 %	74 %	71 %	27 %	42 %
5.	↓	Marseille	France	35 %	60 %	70 %	20 %	41 %
6.	...	Paris	France	35 %	65 %	65 %	35 %	35 %
7.	↑	London	UK	34 %	60 %	63 %	22 %	40 %
8.	↓	Athens	Greece	34 %	54 %	49 %	14 %	40 %
9.	↑	Brussels	Belgium	34 %	73 %	77 %	31 %	36 %
10.	...	Stockholm	Sweden	30 %	59 %	66 %	27 %	33 %

Procjenjuje se da više od 70 % europske populacije živi u gradskim središtima [4] pod gotovo neprekidnim utjecajem onečišćenja zraka i buke uzrokovane cestovnim prometom. No, uz navedena onečišćenja bitno je naglasiti da problem pod nazivom *cruising for parking*¹ uzrokuje više od 30% od ukupnog uobičajenog prometnog zagušenja nastalog uslijed dnevnih putovanja i gužvi zbog radova na cestama, prometnih nezgoda i sličnih prometnih problema, jer traženje slobodnog parkirališnog mjesta u prosjeku traje 20 minuta [5]. Ovo je istraživanje obuhvatilo preko 8000 putnika u 20 velikih svjetskih gradova. Prema drugim provedenim studijama ovaj postotak može biti i puno veći pa tako u dijelu Minhena (Schwabing) prelazi čak 44 % [6], a u dijelu Brooklyna (Park Slope) 45 % [7]. Ovaj fenomen, između ostalog, u domeni uličnog parkiranja predstavlja i značajan čimbenik prometnih nezgoda i sigurnosti na cestama općenito [8]. Prema ranijoj objavi istog autora, studije koje

¹ Uz navedeni naziv u literaturi se koriste i *searching for parking* i *looking for parking* jednako značno.

su obuhvaćale 10 gradova u pet američkih država objedinjene u FHWA izvješću pokazuju da 24 % svih prometnih nezgoda čine nezgode uzrokovane nepažljivim parkiranjem (ulaskom i izlaskom s parkirališnog mjesta), neodgovornim napuštanjem vozila, naglim zaustavljanjem i sl.

Izvješća Europske unije pokazuju da se broj smrtnih slučajeva na prometnicama u 2012. godini smanjio za 9 %. Broj smrtno stradalih iznosio je 28.000, a ozlijeđenih 1,5 milijuna u oko milijun prometnih nezgoda što je društvo koštalo otprilike 130 milijardi eura [9]. Pravovremene prometne informacije o cestovnoj sigurnosti mogle bi dovesti do smanjenja broja smrtno stradalih od 2,7 do 7 % i ozlijeđenih za 1,8 do 6,3 %, odnosno ostvarila bi se ušteda od otprilike 75 do 118 milijuna eura godišnje.

Oko 44 osoba pogine i 1.430 ih je ozlijeđeno uslijed nesreća izazvanih parkiranjem. Prikazivanjem statičkih i dinamičkih informacija koje bi ukazivale na lokaciju parkirališnih prostora te raspoloživost parkirališnih mjesta mogao bi se smanjiti broj incidenata za 40 % i povećati produktivnost za 160 milijuna eura (smanjujući troškove uzrokovane incidentima – za oko 48 milijuna eura, smanjujući vrijeme vožnje potrošeno u traženju slobodnog parkirališnog mjesta – za oko 90 milijuna eura, smanjujući ostale troškove – za oko 24 milijuna eura) [10].

Broj vozila u svijetu u neprestanom je porastu. Očekuje se da će do 2030. godine samo u UK broj vozila doseći brojku od 39 milijuna od čega će oko 2,8 milijuna biti parkirano na uličnim parkiralištima [11]. Prema predviđanjima Royal Automobile Club Foundation te procjeni da svako vozilo parkirano na ulici zahtijeva u prosjeku prostor dužine 5 metara, ovakvo stanje moglo bi rezultirati potražnjom za novih 14.000 kilometara rubnika uz kojeg će se parkirati vozila. Činjenica da se broj prometnica i njihova dužina neće u međuvremenu znatno povećati, dovest će do velikog problema koji će zahtijevati drastične promjene parkirališne politike i upotrebu pametnih sustava koji će je pratiti.

Uz zagušenje prometa, te svoje ekološke i sigurnosne aspekte, kruženje u potrazi za slobodnim parkirališnim mjestom ima i svoj značajan ekonomski utjecaj. U 2010. godini navedena zagušenja prouzrokovala su u Americi 4,8 milijardi sati kašnjenja, 7,2 milijarde litara dodatne potrošnje goriva i trošak od 101 milijardu dolara [12]. Samo u Los Angelesu na potražnju slobodnih parking mjesta potrošilo se 178.000 litara goriva (što je dostatno da se 38 puta obiđe svijet) i proizvelo 730 tona ugljičnog dioksida [13]. Ne treba zaboraviti ni povećanu potrebu za održavanjem prometnica koju uvjetuje intenzivnije korištenje.

Proces migracije stanovništva u gradove je kontinuiran, a samim time i potražnja za parkirališnim mjestima kontinuirano raste. Ulična i izvanulična ponuda parkirališnih mjesta u gradovima gotovo je redovito nedostatna za sve veći broj vozila. Važnost primjene

odgovarajuće strategije upravljanja parkirališnim prostorima može se pronaći i u procjeni da tipično vozilo tijekom dana provede u stanju mirovanja 95 % vremena [14].

Kruženje u potrazi za slobodnim parkirališnim mjestom uzrokuje dodatni stres vozača koji pokušava pronaći najpovoljnije rješenje, najčešće s obzirom na blizinu krajnjeg odredišta (poslovnog prostora, trgovačkog centra, centra za rekreaciju i sl.) i cijenu parkirališnog mjesta. Ponašanje vozača pri izboru vrste i lokacije mjesta za parkiranje, te donošenje konačne odluke ovisi o nizu čimbenika i znatno je složenije i treba mu posvetiti puno više pažnje nego što se to ranije činilo. Uporište za ovu tvrdnju može se pronaći u više istraživačkih radova [15-19].

Rješenja za smanjenje prometnih zagušenja se prije svega pokušavaju pronaći u odgovarajućem odnosu cijene uličnog i izvanuličnog parkiranja. Nadalje, koriste se različiti režimi za naplatu parkiranja, te u vrijeme vršnih opterećenja u pojedinim gradovima cijena vrtoglavo raste (Tablica 2.).

Usklađivanje cijena u odnosu s parkirališnom ponudom i potražnjom ovisi o parkirališnoj politici grada i odnosu ponude i potražnje, no svakako treba uzeti u obzir i činjenicu da na cijenu može utjecati smanjenje broja vozila u gradskom središtu i sl.

Tablica 2. Usporedba cijena uličnog i izvanuličnog parkiranja* [20]

City	Price on-street	Price off-street	Difference
San Fransisco	1.00 \$	1.50 \$	0.50 \$
Los Angeles	1.50 \$	3.30 \$	1.80 \$
Seattle	1.00 \$	8.00 \$	7.00 \$
Boston	1.00 \$	11.00 \$	10.00 \$
New York	1.50 \$	14.38 \$	12.88 \$
Chicago	1.00 \$	13.25 \$	12.25 \$
Tel Aviv	2.00 NIS	20.00 NIS	18.00 NIS

* Podatke o Tel Avivu dodao Dr. Karel Martens u Izraelskoj valuti novi šekel

U osnovne strategije za upravljanje parkiranjem uz različite mehanizme naplate parkiranja spadaju još i regulatorne mjere, elementi fizičkog dizajna i kvaliteta ugovorenih usluga [21]. U praksi se koriste različite kombinacije navedenih strategija kako bi se ostvarili ciljevi određeni gradskim politikama. Upotreba naprednih tehnologija neizbježna je u ostvarenju odabrane kombinacije strategija.

Potražnja za slobodnim parkirališnim mjestom dinamička je veličina, dakle veličina koja se mijenja tijekom vremena, pa se logički nameće potreba za pružanje informacija vozačima

motornih vozila o lokacijama i stanju ponude parkiranja u realnom vremenu. Sustavi pružanja informacija korisnicima o ponudi mjesta za parkiranje počeli su se koristiti u nekim svjetskim gradovima već prije više od 40 godina i mogu se pronaći pod nazivima poput "A Guided Parking System" ili "Dynamic Parking Guidance System" [22]. Dakle, ideja o uporabi specifičnih sustava u svrhu rješavanja prethodno opisanih problema nije novijeg datuma, već se sustavi za upućivanje vozila na parkiranje u različitim izvedbama koriste dugi niz godina. Najprije su ovi sustavi pružali korisnicima samo statičke preputne i putne parkirne informacije. Informacije su bile dostupne putem interneta na osobnim računalima ili u tu svrhu posebno predviđenim mjestima (info kiosk) i putem prometnih znakova koji su najčešće prikazivali samo naziv parkirališnog objekta, smjer, kapacitet i udaljenost. Na posebno uređenim internetskim stranicama mogle su se pronaći informacije u obliku mape na kojoj su označeni parkirališni objekti u neposrednoj blizini odabrane destinacije ili rute kojom će se korisnik koristiti i način na koji se do njih može stići. U svrhu stvaranja odgovarajućeg parkirališnog plana korisnicima su se pružale i informacije poput adrese parkirališnog objekta, kapaciteta, radnog vremena, troškova, načina plaćanja, itd.

Tehnološki napredak omogućio je pružanje dinamičkih informacija korisnicima pa su se sukladno tome počeli koristiti prometni znakovi s promjenjivim sadržajem i dinamičke internetske stranice. Dinamički dio prometnih znakova s promjenjivim sadržajem prikazivao je informaciju o zauzeću parkirališta (npr. u obliku zelenog ili crvenog svjetla, teksta "slobodno" ili "zauzeto" i sl.) ili podatak o broju slobodnih parkirališnih mjesta. Pružane informacije nisu uvijek bile dovoljno precizne i kvalitetne jer su često bile netočne i zakašnjele zbog nesavršenosti sustava, te dostupne samo za zatvorene parkirališne objekte.

Uporabom sustava za informiranje i upućivanje na parkirališna mjesta (*Parking guidance and information system*, PGIS ili PGI sustav), kako se i danas u praksi često nazivaju, moguće je u stanovitoj mjeri unaprijediti proces parkiranja i povećati njegovu uspješnost i učinkovitost.

Daljnji razvoj informacijskih, komunikacijskih i drugih tehnologija (senzora) doveo je do stvaranja takvih sustava koji prikazuju informacije u stvarnom vremenu, otporni su na greške, sposobni su pružati podatke o svakom pojedinom uličnom i izvanuličnom parkirališnom mjestu, identificiraju vozila, omogućavaju naplatu različitim platežnim sredstvima, provode postupak rezervacije i mogu osigurati prikupljene i obrađene informacije svim zainteresiranim skupinama, brinući se pritom o sigurnosti i odgovarajućim ovlastima. Informacije se mogu prikazivati u bilo koje vrijeme i na bilo kojem mjestu (stolna ili prijenosna računala, dlanovnici, tableti, pametni telefoni, uređaji u vozilu, prometni znakovi s promjenjivim sadržajem, razni zasloni). Uz postojeće računalne sustave i internetske stranice počele su se izrađivati i različite mobilne aplikacije.

Vodeći problemi koji prate razvoj sustava za upućivanje vozila na parkiranje i informiranje su iznimno visoki troškovi. Tehnološki napredak nije doveo samo do smanjenja dimenzija senzora, komunikacijskog sklopovlja i uređaja za napajanje već se i cijena opreme znatno smanjila. Time se otvorio prostor za pojavljivanje cijelog niza različitih rješenja za upravljanje parkirališnim prostorima i upućivanje na raspoloživa parkirališna mjesta.

Moderni sustavi koji se danas mogu pronaći na tržištu razlikuju se prije svega po tipu senzora koje koriste za pronalaženje raspoloživog parkirališnog mjesta i tipu komunikacijskih sklopova i protokola. Sustave koji koriste žične i optičke veze gotovo je više sasvim neisplativo upotrebljavati već se u navedenu svrhu koriste bežične mreže osjetila (WSN), redovito s autonomnim napajanjem (baterijama) i ugrađenom sposobnošću pretprocesiranja informacija (mikrokontroler).

Sustavi za upućivanje vozila na raspoloživa parkirališna mjesta koriste različite senzore (induktivne petlje, magnetometre, piezoelektrične kablove, mikrovalne radare, laserske radare, akustična polja, kamere, infracrvene i ultrazvučne senzore [23]), no detekcija popunjenosti parkirališnog mjesta uporabom bežičnih senzorskih mreža najčešće se zasniva na magnetskim [24], [25], [26] i ultrazvučnim sensorima [24], [27], [28], [29].

Nedostaci koji se očituju kod sustava za upućivanje na raspoloživa parkirališna mjesta mogu se prije svega sagledati u slabim ili nikakvim mogućnostima rezervacije parkirališnog mjesta. Dosadašnja iskustva ukazala su na niz problema koji se uočavaju unutar postojećih rješenja, a prvenstveno u slučajevima upravljanja uličnim parkiralištima. U praksi se događaju slučajevi da vozači ne pronađu raspoloživo parkirališno mjesto na koje ih je upućivao sustav jer je u međuvremenu postalo zauzeto. Također, sustav može uputiti više vozača na isto parkirališno mjesto, a da do trenutka pristizanja niti jedan ne uspije parkirati na mjesto predviđeno takvim uputnim sustavom [30].

Upućivanje više vozača u smjeru parkirališta s manjim brojem slobodnih parkirališnih mjesta rezultirat će pojavom koja će umjesto da smanji količinu zagušenja učiniti upravo suprotno. Nadalje, čak i da sustav za upućivanje djeluje s visokoučinkovitim algoritmima pojavljuje se vjerojatnost da se prilikom upućivanja vozila na bilo koje slobodno parkirališno mjesto isključuje potencijalna mogućnost parkiranja na kvalitetnijem, jednako tako slobodnom parkirališnom mjestu [30].

Ugradnja opreme za sprječavanje neovlaštenog parkiranja u svako pojedino parkirališno mjesto na ulici složena je i neisplativa. Rješenja koja uključuju posebne sustave označavanja poput slovnih (MR – Mobile Reservation), vizualnih (podne svjetleće oznake u raznim bojama ovisno o statusu parkirališnog mjesta) i zvučnih (intenzivan zvuk prilikom parkiranja vozila bez rezervacije) nisu pokazala zadovoljavajuće rezultate. Kultura osoba

koje upravljaju motornim vozilima nije na takvoj razini da bi takva rješenja funkcionirala besprijekorno. Iako se u gradskim središtima teži k smanjivanju uličnih parkirališnih mjesta ili njihovom apsolutnom ukidanju – ovaj problem i dalje ostaje otvoren.

Inteligentni transportni sustavi (ITS) mogu značajno doprinijeti čistim, sigurnijim i puno učinkovitijim transportnim sustavima. Zakonodavni okvir (Direktiva 2010/40/EU) usvojen 7. srpnja 2010. ima zadatak ubrzati razvoj inovativnih transportnih tehnologija na području Europe. Ova Direktiva predstavlja važan instrument za koordiniranu implementaciju inteligentnih transportnih sustava u Europi, te ima za cilj uspostaviti međusobno ovisne i djelotvorne ITS usluge ostavljajući pritom državama članicama slobodu odlučivanja u koje će sustave ulagati.

U skladu s navedenom Direktivom Europska komisija mora u razdoblju od 7 sljedećih godina usvojiti specifikacije (funkcionalne, tehničke, organizacijske) kako bi osigurala kompatibilnost, interoperabilnost i kontinuitet ITS rješenja širom EU-a. Jedan od prvih prioriteta bit će prometne i putne informacije.

Europska je komisija 16. prosinca 2008. usvajanjem Akcijskog plana već napravila veliki korak prema implementaciji i uporabi ITS-a u cestovnom prometu (i sučelja prema drugim prometnim oblicima).

PGI sustavi iskorištavaju sve prednosti stvarnovremenskih senzora i komunikacijske infrastrukture kako bi dinamički nadzirali raspoloživa parkirališna mjesta i uspješno navodili zainteresirane vozače motornih vozila. Upravo ta činjenica navela je i autora ovoga teksta da kroz suradnju na projektu pod nazivom *Intelligent Cooperative Sensing for Improved traffic efficiency* (ICSI), razviti potencijalno rješenje opisanih problema na način da se unaprijede postojeći ili izrade novi algoritmi i prometni modeli, te stvori prijedlog strategije upravljanja prometom, a posebice u kontekstu raspoloživih parkirališnih potencijala. U svrhu uspješnog i učinkovitog prijevoza ljudi i roba, koje bi smanjilo prometna zagušenja u urbanim središtima, a time i utjecaj onečišćenja na okolinu, neophodno je usvojiti i odgovarajuće nove prometne politike. One bi trebale između ostalog uključivati i alternativne oblike prijevoza, potaknuti intermodalni promet unutar urbanih centara (npr. biciklima i/ili električnim vozilima) i izgradnju parkirališta blizu postaja javnog gradskog prijevoza ili pružatelja usluga dijeljenog prijevoza (vehicle-sharing stations and inter-modal parking). U okviru ICSI projekta PGI sustav bi predstavljao samo uslužni podsustav koji bi pružao zainteresiranim korisnicima informacije o najbližim raspoloživim parkirališnim mjestima, alternativnim multimodalnim prijevoznim mogućnostima, cijenama i modelima naplate zahvaljujući podacima dobivenim od inteligentnih kooperativnih senzora, uređaja i podsustava koji će ih prikupljati, obrađivati i distribuirati u stvarnom vremenu.

Model razvoja specifičnih informacijsko-komunikacijskih tehnologija predložen u ICSI projektu potaknuo je i ovo istraživanje koje bi svojim rezultatima trebalo opravdati uključivanje te prepoznatljivo djelovati na smanjivanje količine zagušenja na prometnicama u gradskim centrima, a time i na smanjivanje vremena putovanja, razine stresa vozača motornih vozila, količine štetnih onečišćenja i buke, indirektno nastalih nepotrebnih troškova i općenito povećanja sigurnosti u prometu.

1.1. Problem, predmet i objekt istraživanja

Velika većina svjetskih gradskih središta odlikuje se nesrazmjerom parkirališne ponude i potražnje. Broj osobnih vozila koji se, vođeni različitim motivima, pokušavaju dovesti čim bliže atraktivnim gradskim sadržajima, poslovnim ili trgovačkim kompleksima sve je veći, a njime se učestalo stvara dodatni prometni volumen koji je puno veći od kapaciteta prometne mreže. Gradska infrastruktura redovito nije podložna velikim promjenama tako da je mogućnost povećanja parkirališnih kapaciteta jako mala ili gotovo nikakva što sve više smanjuje mogućnost pronalaženja odgovarajućeg parkirališnog mjesta. Rezultat potrage za slobodnim parkirališnim mjestom dodatno opterećuje već zasićene i zagušene prometnice, te se stoga gradske vlasti u suradnji s prometnim stručnjacima odlučuju na upotrebu različitih mjera koje će destimulirati dolazak vozača osobnim vozilima u urbana središta. Strategije koje se u tu svrhu koriste najčešće ograničavaju vrijeme parkiranja, reguliraju cijenu parkiranja i populariziraju neki od alternativnih oblika prijevoza.

Brojni su negativni učinci koje donosi ovakav oblik funkcioniranja prometa u gradskim središtima, a očituje se osim u zagušenju prometnica i u onečišćenju okoline ispušnim plinovima i bukom, smanjivanjem sigurnosti na prometnicama i povećanju prometnih nezgoda i povećanju vremena putovanja.

S obzirom na sve navedene činjenice, pokazuje se da je korisno u svrhu smanjenja prometnog volumena nastalog uslijed traženja slobodnog parkirališnog mjesta pružiti vozačima, čija je intencija ulazak u gradsko središte, informacije o lokacijama uličnih i izvanuličnih slobodnih parkirališnih mjesta.

U skladu s tom tvrdnjom može se postaviti sljedeći problem istraživanja:

'Premda se postojeće strategije i politike koje se primjenjuju u gradovima u određenoj mjeri nose s problematikom nedostatka parkirališnih kapaciteta i utječu na smanjenje zagušenja na prometnicama u gradskim središtima, još uvijek je taj problem dovoljno opsežan te opravdava provođenje znanstvenog istraživanja u svrhu učinkovitijeg upravljanja slobodnim parkirališnim mjestima. Razvoj informacijsko-komunikacijskih tehnologija omogućit će uz

pomoć rezultata znanstvenih istraživanja stvaranje odgovarajućih inteligentnih rješenja koja će još uspješnije i učinkovitije navoditi vozače do slobodnih parkirališnih mjesta, pružati im sve neophodne informacije i time smanjiti negativne učinke suvišne vožnje.'

Sukladno problemu istraživanja definira se i predmet istraživanja ovoga doktorskog rada:

'Sustavno istražiti i konzistentno utvrditi sve relevantne teorijske i praktične značajke upućivanja vozila na raspoloživa parkirališna mjesta, identificirati sve prednosti i nedostatke postojećih i do sada predloženih rješenja, te istražiti mogućnosti primjene i implementacije inteligentnih rješenja koja će biti temeljena na kooperativnim osjetilima i telematičkim sustavima u vozilu.'

Prethodno definirani problem i predmet znanstvenog istraživanja odnose se na nekoliko značajnih objekata istraživanja, i to na: *parkiranje i parkirališne sustave, tehnologije za detektiranje slobodnih parkirališnih mjesta, telematičke sustave u vozilu, sustave za informiranje, navigaciju i upućivanje vozila, inteligentna kooperativna osjetila, inteligentne modele za upućivanje na raspoloživa parkirališna mjesta.*

1.2. Znanstvena hipoteza i pomoćne hipoteze

S obzirom na izneseni problem, predmet i objekt znanstvenog istraživanja postavljena je i temeljna znanstvena hipoteza:

'Inteligentno upućivanje vozila na raspoloživa parkirališna mjesta uporabom telematičkog sustava u vozilu smanjuje potrebu za kruženjem u potrazi za slobodnim parkirališnim mjestom.'

Iz temeljne znanstvene hipoteze koja se direktno odnosi na predmet znanstvenog istraživanja proizlazi i nekoliko pomoćnih hipoteza:

- PH 1:* Inteligentno upućivanje vozila na raspoloživa parkirališna mjesta upotrebom kooperativnog sustava u vozilu smanjuje prometna zagušenja u gradovima.
- PH 2:* Inteligentno upućivanje vozila na raspoloživa parkirališna mjesta upotrebom kooperativnog sustava povećava sigurnost u prometu.
- PH 3:* Inteligentno upućivanje vozila na raspoloživa parkirališna mjesta upotrebom kooperativnog sustava smanjuje vrijeme putovanja.
- PH 4:* Inteligentno upućivanje vozila na raspoloživa parkirališna mjesta upotrebom kooperativnog sustava smanjuje količinu štetnih ispušnih plinova.

1.3. Svrha i ciljevi istraživanja

Glavni cilj je razvoj modela za inteligentno upućivanje vozila na raspoloživa parkirališna mjesta uporabom telematičkog sustava u vozilu koji predstavlja dio istraživanja za razvoj strategije koja će predstavljati osnovu za izgradnju budućih PGI sustava nastalih uporabom naprednih informacijsko-komunikacijskih tehnologija. U svrhu ostvarenja glavnog cilja istraživanja, potrebno je ostvariti i niz sporednih ciljeva poput:

- upoznavanja s postojećim modelima, algoritmima i rješenjima primjenjivim na parkirališnu problematiku
- upoznavanja s problemima koji se postavljaju pred istraživače u navedenom području
- utvrđivanja trenutnog stanja na tržištu sustava za upravljanje parkirališnim mjestima
- optimiziranja uporabe raspoloživih parkirališnih mjesta
- pojednostavljenja procesa parkiranja
- mjerljivog zadovoljstva korisnika usluge
- ublažavanja prometnih zagušenja
- smanjivanje onečišćenja uzrokovanog nepotrebnim kruženjem u potrazi za parkirališnim mjestom i ostale negativne učinke tog fenomena.

Svrha istraživanja je ponuditi poboljšana rješenja za inteligentno upućivanje vozila na raspoloživa parkirališna mjesta pri čemu će posebna pažnja biti posvećena skraćivanju vremena putovanja i traženja slobodnog parkirališnog mjesta, čime će se posljedično povećati zadovoljstvo korisnika usluge, smanjiti onečišćenje ispušnim plinovima i bukom, smanjiti nepotrebna potrošnja goriva, rasteretiti prometnice i parkirališta u urbanim središtima. Dodatno, ovakav pristup ima i svrhu jednostavnije realizacije strategije koja će biti preduvjet za izgradnju budućeg PGI sustava u sklopu ICSI projekta.

1.4. Pregled dosadašnjih istraživanja

Potražnja za raspoloživim parkirališnim mjestima i brojni negativni učinci koji su rezultat ovog fenomena jedan su od vodećih prometnih problema u gradovima širom svijeta [13], [31], [32], [33]. Visok stupanj motorizacije i razvoj gradskih središta, uz slabe mogućnosti povećanja kapaciteta prometnica, doveli su do gotovo svakodnevnih zagušenja prometa u pojedinim dobima dana, te do sve veće potrebe za odgovarajućim rješenjima koja bi taj problem ublažila ili u cijelosti uklonila. Izvori zagušenja mogu biti različiti [34], a njihov značajan čimbenik je i potražnja za raspoloživim parkirališnim mjestom. Gradske se vlasti u

suradnji sa svim ostalim zainteresiranim stranama na različite načine pokušavaju oduprijeti širenju posljedica ovoga problema. U skladu s time stvaraju se, mijenjaju i nadopunjuju strategije upravljanja zagušenjima, donose nove prometne politike i primjenjuju sve modernija prometna rješenja [35], [36], [37].

Jedno od rješenja koje se sve više primjenjuje su različiti inteligentni parkirališni sustavi za upućivanje vozila na raspoloživa parkirališna mjesta. Oni pružaju vozačima motornih vozila dinamičke informacije o stanju u prometu unutar kontroliranih područja, te im ukazuju na raspoloživost slobodnih parkirališnih mjesta i upućuju ih na parkiranje optimalnim rutama. Prvi se takvi sustavi pod nazivom sustavi za informiranje i upućivanje na parkirališna mjesta (PGI sustavi) počinju pojavljivati početkom 70-ih godina u Europi [38], a zatim u Japanu i Sjedinjenim Američkim Državama. Osnovna je zadaća takvih sustava smanjivanje vremena koje vozači provode u potrazi za parkiralištem i količine zagušenja koje izazivaju, a time i svih ostalih indirektnih posljedica poput povećane emisije štetnih plinova, buke, nesreća na cesti i stresa vozača. Sustavi su u početku bili skromnih mogućnosti i najčešće su pomoću statičkih znakova usmjeravali vozače u smjeru parkirališta u gradskim središtima. Informacije koje su pružali vozačima bile su prilično oskudne i svodile su se na stanje (puno ili prazno) i smjer u kojem se nalazio određeni parkirališni prostor. Kasnije inačice sustava koristile su znakove s promjenjivim porukama kako bi korisnicima pružili informaciju o očekivanom broju raspoloživih parkirališnih mjesta na određenom parkiralištu i/ili mogućnostima plaćanja i cijeni parkiranja. U svom radu Obdeijn [39] uspoređuje učinkovitost PGI sustava u 3 europska i 2 japanska grada i pokazuje da udio vozača koji mijenjaju svoju odluku o krajnjem odredištu (parkirališnom mjestu) na osnovi informacija PGI sustava radnim danom iznosi od 10 % do 16 %, a nedjeljom od 15 % do 18 %. Uspješnost, učinkovitost i opravdanost takvih sustava teme su brojnih znanstvenih radova [38], [40], [41].

Daljnji tehnološki napredak omogućio je razvoj velikog broja različitih pristupa i rješenja za probleme uzrokovane parkiranjem. Inteligentni ili pametni parkirni sustavi, kako se danas najčešće nazivaju, sposobni su pružiti informaciju o svakom pojedinom uličnom i izvanuličnom parkirališnom mjestu koje je opremljeno odgovarajućim osjetilima, sugerirati vozaču optimalnu rutu do odabranog mjesta i precizno ga navoditi putem odgovarajućeg uređaja u vozilu. Informacije o raspoloživom parkirališnom mjestu mogu uključivati cijenu parkiranja i prihvatljive oblike plaćanja te druge potencijalno korisne informacije poput maksimalno dopuštenog vremena parkiranja, mogućnostima rezervacije, itd.

Inteligentni parkirni sustavi u osnovi se sastoje od podsustava za otkrivanje prisustva vozila, podsustava za računalno upravljanje, podsustava za distribuciju informacija i komunikacijskog podsustava. U svrhu otkrivanja prisustva vozila mogu se koristiti različita osjetila [23], no najčešće se u garažnim objektima koriste ultrazvučna osjetila, a na

otvorenim parkiralištima i uličnim parkirališnim mjestima magnetska. Tehnološki razvoj osjetila doveo je do njihove minimizacije, pa ih je moguće naći i u MEMS i NEMS izvedbi (mikro i nanoelektromehanička osjetila). Jednostavnija ugradnja i puno prihvatljiviji troškovi omogućili su njihovu primjenu i na uličnim parkirališnim mjestima. Ova osjetila mogu biti opremljena s odgovarajućim izvorima napajanja, te uz svoju osnovnu funkciju raspolagati i s: obradom podataka i bežičnom komunikacijom. To ih čini prikladnima da budu dio bežične mreže osjetila [42], [43], [44] ili arhitekture interneta stvari (IoT) [45], [46].

U centralnom se dijelu upravljačkog sustava obrađuju prikupljene informacije i proslijeđuju podsustavima za distribuiranje, te se prikazuju na prometnim oznakama s promjenjivim porukama, infopanelima, infokioscima, zaslonima mobilnih uređaja ili jedinicama u vozilu [47]. Na osnovi raspoloživih informacija inteligentni algoritmi s obzirom na karakteristike vozača pronalaze najprikladnije mjesto za parkiranje [48], [49], [50] te odgovarajuću rutu [51], [52], [53], [54], [55], kojom će ga po potrebi navoditi.

Značaj uvođenja PGI sustava ilustrira se dvama praktičnim primjerima u hrvatskim gradovima. U gradu Zagrebu je 1998. godine za potrebe izrade *Prometne studije grada Zagreba* ("Traffic Study for the City of Zagreb") provedeno ispitivanje i mjerenje količine vremena koje vozila s velikom vjerojatnošću provode u traženju slobodnog parkirališnog mjesta (vozila koja se pojavljuju dva ili više puta na promatranom području u relativno kratkom vremenu). Iste je godine slično mjerenje izvršeno i u gradu Rijeci za potrebe izrade *Studije automatskog upravljanja prometom u gradu Rijeci* ("Study on Automatic Traffic Management in the Town of Rijeka"). U prijedpodnevnim je satima radnim danom ovaj oblik vožnje u Zagrebu iznosio čak 30 %, dok je u Rijeci iznosio 17 %. Nepotrebno prometno opterećenje nastalo navedenim oblikom vožnje i izraženo jezikom prometnih modela u gradu Zagrebu iznosilo je 6,4 km, a u Rijeci oko 2,2 km. Ove vrijednosti odgovaraju za prosječno zauzeće prostora od 6 m po jednom vozilu. Ekološki učinci potencijalne primjene PGI sustava vidljivi su u smanjenju buke (manji broj vozila u određenim segmentima prometne mreže), te smanjenju potrošnje goriva i emisije ispušnih plinova (kraće vrijeme putovanja i povećanje protočnosti) [56].

Sustavi koji se temelje na *ad hoc* mrežama vozila predmet su intenzivnih istraživanja u posljednjih nekoliko godina [57], [58], [59], pa se predviđa da će se prva vozila i odgovarajući sustavi pojaviti ubrzo na tržištu. Jedan od poznatih proizvođača vozila je 2012. godine u Njemačkoj u pokrajini Rhine-Main napravio veliko pokusno područje koje je uključivalo 120 povezanih vozila. Istraživanja i testiranja koja su započela još 2006. godine na C2X sustavima provedena su i u gradu Palo Alto, California, kako bi se sustavi prilagodili i američkom tržištu. Nakon navedenog opsežnog i do tada vjerojatno najvećeg europskog testiranja sličan test

nedugo zatim provodi i U.S. Department of Transport (DoT) u regiji Ann Arbor, Michigan, koje svojim programom pod nazivom *Connected Vehicle Safety Pilot Model Deployment Program* obuhvaća čak 3000 vozila.

Uz već navedene studije koje se bave problemom parkiranja poput Polakove i Waerdenove, mogu se istaći i studije Hunta i Teplyja [60], Millera [61], Lambe [62], Hessa i Polaka [63], Guana i suradnika [64], Harmatucka [65], te Borgersa i suradnika [66]. Od domaćih radova mogu se izdvojiti autori koji se bave istraživanjem učinkovitosti naplate parkirališnih usluga [67], primjenom telematičkih uređaja u parkirnim sustavima [68], optimizacijom kapaciteta gradskih parkirališta [69] i politikom parkiranja općenito [70]. Osim konferencijskih radova i radova u časopisima i zbornicima, podršku istraživanju pružaju i knjige iz navedenog područja [71], [72], [73], [74], [75], [76].

1.5. Znanstvene metode

U ovome se doktorskom radu u skladu s objektima istraživanja koristi metoda matematičkog modeliranja za modeliranje tehnologija za traženje raspoloživih parkirališnih mjesta, ponašanja vozača u odnosu na dinamiku parkiranja i postupaka za inteligentno upućivanje vozila, a za provjeru postavki i rezultata, eksperimentalna metoda i metoda simulacije. Metode inteligentne identifikacije, fuzije podataka, aproksimacije i predikcije koriste se za identifikaciju međuovisnosti odabranih značajnih parametara sustava. Za modeliranje algoritama inteligentnog upućivanja vozila koriste se različite algoritamske strukture. Metode mjerenja i projektiranja dinamičkih sustava u realnom vremenu koriste se za simulaciju prikupljanja i obrade raspoloživih podataka sustava. Za razvoj simulacijskih modela, testiranje i verifikaciju koristi se programsko rješenje PTV VISSIM. Sva potrebna mjerenja i ispitivanja provedena su uz pomoć dostupnih resursa u Laboratoriju za procesna mjerenja i upravljanje na Pomorskom fakultetu u Rijeci.

Za potrebe znanstvenog istraživanja, analize, sinteze i prezentacije rezultata istraživanja primjenjuje se kombinacija više istraživačkih metoda. Pri opisu problema i donošenju temeljnih postavki za vrednovanje mogućnosti primjene sustava koristi se metoda deskripcije i dedukcije, a za donošenje općih zaključaka o topologijama i značajkama sustava induktivna i deduktivna metoda. U okviru sistematizacije i usporedne analize primjenjuje se metoda klasifikacije, te formalne i komparativne analize. Od ostalih metoda treba izdvojiti metodu kompilacije za pregled dosadašnjih istraživanja i radova te metodu intervjuiranja za prikupljanje potrebnih informacija od strane korisnika sustava. Za prihvatanje ili opovrgavanje postavljenih teza vodeću ulogu imaju metode dokazivanja i opovrgavanja.

1.6. Struktura rada

Sukladno svrsi i ciljevima istraživanja i s obzirom na problem, predmet i objekte, doktorski je rad podijeljen u osam poglavlja koja čine jednu funkcionalnu cjelinu.

U prvom dijelu, UVODU, definirani su problem, predmet i objekti istraživanja, postavljene su znanstvene hipoteze (glavna i pomoćne), opisana svrha i ciljevi istraživanja, dan pregled dosadašnjih istraživanja te navedene znanstvene metode koje su se koristile i obrazložena struktura rada.

U drugom dijelu pod naslovom PARKIRANJE I PARKIRALIŠTA opisuju se obilježja parkiranja i problematika parkiranja. Zatim su prikazane metode upravljanja parkiranjem i rješenja koja se u tu svrhu koriste. Kao jedan od osnovnih načina za rješavanje parkirališne problematike navodi se sustav za upućivanje na raspoloživa parkirališna mjesta i opisuju njegove inačice.

NAPREDNI SUSTAVI ZA INFORMIRANJE PUTNIKA, u trećem dijelu, opisuju se uporabom različitih tehnologija koje se koriste u tu svrhu te se posebno ističe kooperativan pristup detektiranju slobodnih parkirališnih mjesta. Uz napredna osjetila prikazuju se i tehnologije za lociranje vozila i navigaciju. Na kraju su opisani sustavi za navigaciju i upućivanje vozila.

U poglavlju KOOPERATIVNI INTELIGENTNI TRANSPORTNI SUSTAVI U CESTOVNOM PROMETU navode se postojeći sustavi za informiranje, navigaciju i upućivanje vozila s osvrtom na kooperativni pristup pri prikupljanju prometnih i navigacijskih informacija. Prikazana je arhitektura kooperativnih sustava i naglašena komunikacija kao jedan od bitnih čimbenika svojstva kooperativnosti. Na kraju je prikazana ICSI arhitektura sustava koja je nastala u sklopu projekta u okviru kojeg je i nastao ovaj rad.

MODELI IZBORA RUTE, kako je naslovljen peti dio, predstavljaju različite matematičke modele za pronalaženje odgovarajuće rute nakon odabranog skupa mogućih ruta i razmatranja svih alternativa. Navedene su različite metode koje se koriste u rutnim vodičima i sustavima za navigaciju te naglašene njihove prednosti i nedostaci.

Šesti dio pod nazivom NAPREDNI MODEL UPUĆIVANJA VOZILA NA RASPOLOŽIVA PARKIRALIŠNA MJESTA obuhvaća prije svega modeliranje tehnologija za traženje raspoloživih parkirališnih mjesta, ponašanja vozača s obzirom na dinamiku parkiranja i postupaka za inteligentno upućivanje vozila. Prikazuje se klasični model traženja raspoloživog parkirališnog mjesta, a zatim se izrađuje poboljšani algoritam upućivanja s mogućnošću korekcije odabranog prometnog pravca u realnom vremenu i prikazuje razvoj poboljšanog modela telematičkog sustava u vozilu za inteligentno upućivanje vozila uz upotrebu inteligentnih kooperativnih osjetila.

Sedmi dio s naslovom EVALUACIJA USPJEŠNOSTI NAPREDNOG MODELA ZA UPUĆIVANJE VOZILA predstavlja testiranje i ocjenjivanje predloženih koncepata razvojem simulacijskog modela. U tu svrhu određuju se postavke za simulacije te pretpostavke i ograničenja modela. Definira se niz scenarija i provodi simulacijsko modeliranje. Postavljaju se kriteriji za ocjenu uspješnosti te se analiziraju i ocjenjuju dobiveni simulacijski rezultati uporabom metode komparativne analize predloženog modela i odabranih postojećih rješenja.

U posljednjem su dijelu rada prezentirani svi relevantni ZAKLJUČCI. Izneseni zaključci predstavljaju dokaze na temelju kojih su prihvaćene postavljene hipoteze. Također, u ovome se dijelu daju preporuke za daljnja istraživanja na odnosnom području i smjernice za razvoj odgovarajućih strategija i budućih inteligentnih parkirališnih sustava.

Nakon iznesenog sadržaja svih sedam dijelova ovoga doktorskog rada, popisane su sve korištene reference (literatura), kratice, oznake i simboli, indeksi, slike i tablice. Na samom kraju priložen je životopis doktoranda.

2. PARKIRANJE I PARKIRALIŠTA

Povećanje broja vozila i visok stupanj motorizacije razvijenih zemalja svijeta rezultira problemima u prometu, jer gradovi nisu predvidjeli tolika prometna opterećenja. Štoviše, veliki svjetski gradovi nastali su prije nego što su se motorna vozila mogla i zamisliti, pa se stoga takav učinak teško mogao predvidjeti. Ovaj se problem ne odnosi samo na vozila u pokretu kojima je u značajnoj mjeri otežano kretanje prometnicama unutar gradskih središta već i na tzv. promet u mirovanju koji zapravo predstavljaju parkirana vozila. Postojeći parkirališni kapaciteti u velikom broju slučajeva ne zadovoljavaju ni trenutne potrebe u gradovima pa će vrlo teško uspjeti zadovoljiti potrebe koje će nastati u budućnosti. Prostore za nova parkirališta i garaže gotovo je nemoguće pronaći u gradskim središtima već se u tu svrhu može jedino izvršiti prenamjena objekata, odnosno rušenje nekog od postojećih objekata kako bi se sagradio prostor za parkiranje ukoliko to ne predstavlja problem s kulturološko-povijesnog aspekta.

Nedostatak dostatnog kapaciteta prometnica potiče ideju uklanjanja uličnih parkirališnih prostora kako bi se taj problem u nekoj mjeri ublažio, no to svakako rezultira još većim parkirališnim problemom dok se ne osigura dovoljno parkirališnog prostora izvan kolnika. Raspoloživi parkirališni kapaciteti nisu jedini prepoznat problem. Smještaj postojećih parkirališnih mjesta također može značajno utjecati na propusnu moć ulica i normalan prometni tok. Kolone vozila koje se mogu formirati na prilazima garaža ili parkirališta i na taj način nepovoljno utjecati na odvijanje prometa. Vozila koja traže slobodno parkirališno mjesto uz rub prometnice često mijenjaju dinamiku svog kretanja, što se također odražava na poželjan jednoličan tok prometa. Nerijetko se i sasvim zaustavljaju kako bi se parkirala vožnjom unazad čime zaustavljaju sav promet jednim prometnim trakom.

Promet u mirovanju, odnosno parkiranje vozila u gradovima i naseljima preraslo je u vrlo složen problem s kojim se suočavaju gradske vlasti mnogih gradova. Što je veći nedostatak odgovarajućih parkirališnih mjesta to je veća pojava nepropisnog parkiranja. Neodgovorni vozači ne parkiraju svoja vozila samo na mjestima za invalide i osobe s posebnim potrebama već doslovno gdje god stignu. Tako se nepropisno parkirana vozila između ostalog mogu pronaći na pješačkim prijelazima, uz prometna raskrižja, uz kontejnere za smeće, na autobusnim i taksi postajama, na područjima ograničenog parkiranja ili područjima zabrane, na pločniku, na dječjim igralištima ili dvostruko parkirana uz već zauzeta parkirališna mjesta. Gradske vlasti pokušavaju u suradnji s komunalnim društvima, agencijama, policijom i drugim zainteresiranim stranama stati na kraj ovome problemu uporabom različitih regulatornih mjera, strategija i politika parkiranja te time riješiti izraženi nesrazmjer između

broja zahtjeva za parkiranje s jedne strane ili parkirališne potražnje i raspoloživog broja parkirališnih mjesta s druge strane ili ponude parkiranja.

2.1. Obilježja parkiranja

Parkiranje predstavlja aktivnost smještanja vozila i ostavljanje vozila bez vozača i putnika na određeno vrijeme ograničeno vremenom dolaska i vremenom odlaska. Za razliku od parkiranja, zaustavljanje vozila je svaki prekid kretanja vozila na cesti u trajanju do tri minute pri kojem vozač ne napušta vozilo, osim prekida koji se čini da bi se postupilo po znaku ili pravilu kojim se upravlja prometom.

Infrastrukturu za parkiranje čine prostori i objekti koji su namijenjeni i tehnički opremljeni za parkiranje vozila. Parkirališno mjesto je površina namijenjena, projektirana, uređena, označena i tehnički opremljena za parkiranje. Sva infrastruktura za parkiranje unutar određenog područja predstavlja i njegovu parkirališnu ponudu. Parkirališna potražnja je ukupan broj vozila koja na određenom području u određenom vremenu traže raspoloživo parkirališno mjesto. Prema prostoru gdje su smještena parkirališna mjesta mogu se podijeliti na:

- ulična parkirališna mjesta
- izvanulična parkirališna mjesta.

Izvanulična parkirališna mjesta mogu se nadalje podijeliti na:

- parkirališta,
- garaže.

Izvanulična parkirališna mjesta mogu imati objedinjen ulaz i izlaz vozila, ili se oni mogu realizirati odvojeno na jednom ili više mjesta. Ovisno o namjeni parkirališta i garaža potrebno je posebnu pažnju posvetiti objektima i područjima od interesa prilikom planiranja i izgradnje kako bi njihov smještaj bio optimalan (npr. ako se radi o garaži ili parkiralištu trgovačkog centra onda je to mjesto s kolicima za kupovinu, ulaz u objekt, mjesto za naplatu po potrebi i sl.).

Gradovi s manjim brojem stanovnika rijetko imaju uređene garažne prostore zbog visoke cijene izgradnje takvih objekata. U tablici 3. prikazana je ovisnost broja raspoloživih parkirališnih mjesta o veličini grada. Iz prikazanih se podataka može zaključiti da broj uličnih parkirališnih mjesta u odnosu na broj stanovnika kontinuirano opada, a broj garažnih mjesta raste.

Tablica 3. Broj parkirališnih mjesta u odnosu na veličinu grada

Broj stanovnika u promatranim gradovima (u 1000)	Mjesta za parkiranje					
	ulična parkirališna mjesta		parkirališta		garaže	
	broj	%	broj	%	broj	%
10 – 25	1090	41	1530	58	10	0
25 – 50	1430	36	2420	61	140	4
50 – 100	1610	35	2790	60	260	6
100 – 250	2130	28	4760	62	820	11
250 – 500	2450	20	7910	64	1940	16
500 – 1000	3200	14	12500	55	6900	31
preko 1000	8000	14	32200	55	18600	32

Izvor: Highway research board: "Parking principles", Special Report No. 125, USA, 1971.

Motivi za parkiranje su primarni razlozi zbog kojih korisnik vozila parkira vozilo na promatranom području i mogu biti:

- stanovanje – parkiranje zbog dolaska na mjesto stalnog boravka
- posao – parkiranje zbog dolaska na radno mjesto
- poslovni posjet – parkiranje zbog odlaska u poduzeće koje ne predstavlja radno mjesto (poslovni sastanci i sl.)
- privatni posao – parkiranje zbog obavljanja privatnog posla (plaćanje računa i sl.)
- kupovina – parkiranje zbog odlaska u trgovinu
- rekreacija – parkiranje zbog pasivne rekreacije (posjete muzeju, kazalištu, biblioteci i sl.) ili aktivne rekreacije (amaterske sportske aktivnosti)
- ostalo – svi ostali razlozi koji ne spadaju u prethodno navedene.

Utjecaj na parkiranje imaju i objekti smješteni u prostornu strukturu gradskih središta ovisno o svojem sadržaju. Osnovne karakteristike objekata s obzirom na parkirališnu problematiku su stupanj atraktivnosti i vrijeme trajanja atraktivnosti. Stupanj atraktivnosti može se prikazati kao odnos između jednovremenskih zahtjeva u vremenu trajanja atraktivnosti i jednovremenskih zahtjeva izvan vremena trajanja atraktivnosti. Vrijeme trajanja atraktivnosti je razdoblje u kojem korisnici sadržaja zadovoljavaju svoje potrebe.

Uz navedene čimbenike redovito se u istraživanjima koriste i parametri koji predstavljaju gustoću stanovništva na promatranom području i broj vozila po domaćinstvu.

Prema dužini trajanja parkiranja se mogu podijeliti na:

- jako kratka parkiranja (15 do 30 minuta)
- kratka (30 do 120 minuta)
- srednje duga (2 do 6 sati)
- duga (6 do 10 sati)
- jako duga (više od 10 sati).

Trajanje parkiranja Δt_p je vremenski interval zadržavanja vozila na parkirališnom mjestu od početka parkiranja t_1 do napuštanja parkirališnog mjesta t_2 izraženo u odgovarajućim vremenskim jedinicama. Srednje trajanje parkiranja na M parkirališnih mjesta τ je prosječno zadržavanje vozila na promatranim parkirališnim mjestima i u promatranom intervalu Δt , odnosno

$$\tau = \frac{\sum_{i=1}^M \sum_{j=1}^{k_i} [(t_2)_{ij} - (t_1)_{ij}]}{\sum_{i=1}^M k_i}, \quad (1)$$

gdje su:

- M – ukupan broj promatranih parkirališnih mjesta za koja se računa srednje trajanje parkiranja
- $(t_1)_{ij}$ – vrijeme dolaska j -tog vozila na i -to mjesto za parkiranje
- $(t_2)_{ij}$ – vrijeme odlaska j -tog vozila sa i -tog mjesta za parkiranje
- k_i – broj ostvarenih parkiranja na i -tom mjestu za parkiranje u razdoblju Δt .

Akumulacija parkiranja [75] je broj parkiranih vozila na određenoj površini u određenom trenutku. Ona predstavlja mjerilo potražnje za parkiranjem. Parkirališni volumen [160] je ukupan broj jedinstvenih vozila parkiranih na promatranom području u danom razdoblju. Stupanj atraktivnosti nekog područja k_{atr} izračunava se kao odnos između akumulacije parkiranja na početku razdoblja trajanja atraktivnosti A_0 i maksimalne akumulacije parkiranja u razdoblju trajanja atraktivnosti A_{max} , odnosno

$$k_{atr} = \frac{A_0}{A_{max}}. \quad (2)$$

Koeficijent iskorištenja promatranog broja mjesta za parkiranje bio bi

$$k_{isk} = \frac{A}{M}, \quad (3)$$

gdje je A akumulacija parkiranja.

Prosječan koeficijent iskorištenja ili indeks parkiranja koristi se za ocjenu uspješnosti korištenja određenog kapaciteta za parkiranje. Može se izračunati kao

$$k_{isk_{pros}} = \frac{\text{opterećenje parkiranja}}{\text{kapacitet parkiranja}} \cdot 100, \quad (4)$$

gdje je opterećenje parkiranja [voz/h] područje ispod krivulje akumulacije i može se dobiti umnoškom broja vozila koja zauzimaju parkirališni prostor u svakom vremenskom presjeku A_j s duljinom vremenskog intervala T , a kapacitet parkiranja ukupan broj raspoloživih sati za parkiranje na M parkirališnih mjesta u razdoblju Δt . Dakle, prosječan koeficijent iskorištenja može se dobiti iz izraza

$$k_{isk_{pros}} = \frac{\sum_{j=1}^m A_j \cdot T}{M \cdot \Delta t} \cdot 100, \quad (5)$$

Obrt ili izmjena parkiranja k je ostvareni broj parkiranja na jednom parkirališnom mjestu u promatranom vremenu Δt . Srednji broj izmjena po jednom parkirališnom mjestu k_{sred} na M raspoloživih parkirališnih mjesta izračunava se pomoću izraza

$$k_{sred} = \frac{\sum_{i=1}^M k_i}{M}, \quad (6)$$

gdje su:

k_{sred} – srednji broj izmjena parkiranja u promatranom vremenu Δt po jednom parkirališnom mjestu

k_i – broj ostvarenih izmjena parkiranja na i -tom parkirališnom mjestu

M – broj promatranih parkirališnih mjesta za koja se računa srednji broj izmjena.

Udaljenost za pješaćenje L_p je udaljenost koju vozač prijeđe pješice od parkirališnog mjesta do krajnjeg odredišta. Ovo je obilježje vrlo značajno pri izboru lokacije za izgradnju parkirališta ili garaže. Udaljenost za pješaćenje ovisi o veličini grada, motivu i trajanju parkiranja. Razvojem grada povećava se i prihvatljiva udaljenost za pješaćenje [75]. Zbog

relativno visokih cijena parkiranja mnogi su vozači spremni duže pješачiti i parkirati na jeftinijim parkirališnim mjestima. Prihvatljiva duljina pješaćenja ovisi o cijelom nizu čimbenika poput dobne strukture vozača, vremenskih prilika, navika za pješaćenjem, doba dana, doba godine, raspoloženja vozača, svrhe vožnje, cijene parkiranja, činjenice žuri li se ili ne vozaču, te drugih [76].

2.2. Upravljanje parkiranjem

Sustavno upravljanje parkiranjem, poput naplate cestarina i ostalih pristupa koji se zasnivaju na prometnoj potražnji, može utjecati na prometno zagušenje i na taj način smanjiti potražnju za putovanjem u promatrano područje. Elastičnost, kao jedna od karakteristika ovoga pristupa rješavanju problema zagušenja u gradskim središtima, omogućuje precizno usmjeravanje na ciljanu skupinu u odnosu na prostor i vrijeme. Prometna zagušenja izračunavaju se pomoću parametara prometnog toka poput protoka, prosječne brzine i prosječne gustoće [161].

Upravljanje parkiranjem je općenito prihvaćeno kao način za racionalno korištenje ograničenog parkirališnog prostora u područjima s visokom aktivnošću (npr. ograničena na maksimalno 2 sata parkiranja). Ako se koristi neovisno o drugim mjerama, sveopća javnost ga je manje spremna prihvatiti u smislu mjere za reguliranje ukupne upotrebe osobnih vozila i stoga će biti znatno manje učinkovit u ublažavanju zagušenja u gradskim središtima.

Dva najzastupljenija pristupa koja se u okviru upravljanja parkiranjem koriste u svrhu smanjivanja prometnih zagušenja su ograničenje broja raspoloživih parkirališnih mjesta i povećanje cijene parkiranja. Ograničenje broja iskoristivih ili raspoloživih parkirališnih mjesta utječe i na smanjenje broja vozila na prometnoj mreži. Jedan od indirektnih oblika kontrole pristupa užoj gradskoj jezgri može biti i parkirališna politika kojom će se spriječiti ili dozvoliti upotreba uličnih i izvanuličnih parkirališnih prostora, iako sama po sebi ne predstavlja mjeru kontrole pristupa.

Jedan od vodećih problema koji indirektno uzrokuju prometna zagušenja u velikim urbanim sredinama su nekontrolirana i besplatna parkirališna mjesta uglavnom u okviru poslovnih objekata u užem centru grada. Takve potencijalne mogućnosti privlače vozila u urbana središta i negativno utječu na napore koji su uloženi u promociju korištenja alternativnih mogućnosti prijevoza u gradu. Neovisno o tome, slaba parkirališna ponuda u odnosu na visok stupanj korištenja vozila vode prema kruženju, odnosno traženju raspoloživog parkirališnog mjesta. Stoga, upravljanje parkiranjem, kao neizostavan dio ukupne strategije upravljanja potražnjom, predstavlja bitan čimbenik stvaranja ravnoteže između ponude i potražnje.

Upravljanje parkiranjem u urbanim sredinama nosi sa sobom i niz nelogičnosti. S jedne strane gradovi žele osigurati visok stupanj pristupačnosti, uključujući pritom i pristupačnost osobnim vozilom, dok se istovremeno ne žele preplaviti prometom i otvoriti se prema svima s više odgovarajućih parkirališnih prostora. Također, prepoznatljiva je razlika između količine parkirališnog prostora koju lokalne vlasti odgovorne za promet u gradu smatraju optimalnom i one razine koju poslovni subjekti (a redovito i ostatak lokalnih vlasti) smatraju neophodnom za njihovu održivost i nesmetan rad. Upravo su navedeni razlozi uzrok uobičajenih nesuglasica između lokalnih vlasti koje u načelu kontroliraju ulična parkirališna mjesta i privatnog sektora koji najvećim dijelom kontrolira izvanulična parkirališta. Svakako, posebnu pažnju treba obratiti i na razliku između očekivanja lokalnog stanovništva prema raspoloživim uličnim parkirališnim mjestima i onih koji u gradsko središte dolaze zbog svojih aktivnosti (posla, kupovine, rekreacije, zabave i dr.).

Ove su nelogičnosti, nesuglasice i neusklađenosti često rezultirale gotovo jednako tako nesuvislim i nedosljednim parkirališnim pravilima i politikama čime su se u prošlosti ugrožavale strategije upravljanja zagušenjima. Rješenje navedene situacije može se potražiti u sveobuhvatnom pristupu upravljanju parkiranjem koji će se znati nositi s navedenom problematikom i biti jedan od ključnih elemenata uravnotežene strategije upravljanja zagušenjima.

Često međusobno komplementarne, mnoge su parkirališne strategije koje se mogu pojaviti kao podrška politikama upravljanja zagušenjima. One obuhvaćaju mjere orijentirane na općepoznata ulična i izvanulična parkirališta i mjere koje nastoje indirektno upravljati privatnim parkirališnim prostorima poput parkirališnih prostora u sklopu raznih poslovnih objekata i komercijalnih odredišta.

Glavna je uloga upravljanja parkiranjem osiguravanje određenog broja parkirališnih mjesta, te kontroliranje, reguliranje i ograničavanje njihove upotrebe. Broj parkirališnih mjesta se na određenim područjima limitira i dodjeljuju se prava povlaštene upotrebe parkirališnih mjesta za lokalno stanovništvo i vozila s više putnika. Upravljanje ponudom parkirališnih mjesta podrazumijeva i određivanje lokacije garaža na ključnim lokacijama u gradu uključujući i pružanje informacija korisnicima o količini i raspoloživosti slobodnih parkirališnih mjesta, čime se osigurava mogućnost ograničavanja broja uličnih parkirališnih mjesta i reducira zagušenje koje nastaje uslijed kruženja u potrazi za raspoloživim parkirališnim mjestom. Naposljetku treba uložiti potrebne napore kako bi se u čim većoj mjeri poštivali odgovarajući propisi.

U svrhu izbjegavanja negativnih učinaka koji mogu nastati provedbom politike upravljanja parkiranjem, treba uzeti u obzir sljedeće:

- uspješno upravljanje parkiranjem temelji se na provođenju politike naplate parkiranja, no u nastojanjima da se održi odgovarajuća razina pristupačnosti treba postojati svijest o potencijalnim kontraproduktivnim učincima i postupati u skladu s time;
- nužna je dosljednost u primijenjenoj praksi i politici cijena u cijelom urbanom području, a ne samo u glavnom zagušenom dijelu određenog gradskog središta – strategija upravljanja parkiranjem treba se svuda sustavno provoditi;
- javni i privatni pružatelji usluga parkiranja trebaju surađivati i djelovati u sklopu jedinstvenog programa upravljanja parkiranjem kako bi se održala garancija ravnomjerne ponude;
- u svrhu učinkovitog korištenja parkirališnih objekata i izbjegavanja stvaranja nepotrebnog prometa izazvanog traženjem slobodnog parkirališnog mjesta, korisnicima treba pružiti odgovarajuće i precizne informacije o raspoloživim parkirališnim mjestima;
- upravljanje parkirališnim mjestima i određivanje cijena parkiranja treba biti u skladu s:
 - pozicijom (udaljenost od područja od interesa, npr. gradskog središta)
 - trajanjem parkiranja i odgovarajućom dobi dana
 - tipom korisnika i njihovim aktivnostima (posjet, posao, stanovanje, kupovina, dostava, ...)
 - poticanjem vozača na prijevoz više putnika (povlastice za vozila s više od jednog putnika)
 - mogućnostima upotrebe integriranih višenamjenskih parkirališnih objekata koji mogu uslužiti više korisnika na manjem prostoru od pojedinačnih parkirališnih mjesta (postoji mogućnost dijeljenja parkirališnih mjesta između grupe korisnika na specifičnom području u ovisnosti o njihovim dnevnim potrebama za parkiranjem, odredištima i dobi dana).

Politika parkiranja ima i vrlo velik utjecaj na ponašanje vozača i putnika. U ovisnosti o odrednicama prihvaćene parkirališne politike oni će mijenjati modove prijevoza, prilagođavati trajanje boravka na određenoj lokaciji ili vrijeme putovanja i odlučivati se na izbor drugih parkirališta. Stoga politika parkiranja kao jedna od mjera može doprinositi

upravljanju zagušenjima, utjecati na uštedu ukupnog vremena provedenog na putovanju i smanjenje emisije štetnih plinova i buke.

Upravljanje parkiranjem obuhvaća i tzv. *Park and ride* (P+R ili P&R) objekte koji su smješteni u predgrađu i predstavljaju parkirališta vezana za javni prijevoz putnika, te na taj način omogućavaju svim putnicima koji su se uputili u neko gradsko središte ostaviti svoja vozila na parkiralištu i koristiti alternativne mogućnosti prijevoza poput autobusa, tramvaja, trolejbusa, vlaka i sl. Navedeni objekti mogu se koristiti i u svrhu dijeljenja vozila (carpooling, car-sharing).

U pojedinim europskim zemljama lokalne vlasti u suradnji s poslovnim sektorom potiču ostavljanje osobnih vozila izvangradskih središta na način da poduzeća financiraju trošak parkiranja zaposlenika ukoliko se odluče za navedeni model. Upravljanje parkiranjem je u navedenom primjeru mjera kojom se potiče određena grupa korisnika smanjenju upotrebe svojih osobnih vozila. Stoga je za uspješno upravljanje parkiranjem potrebno osigurati kvalitetan javni prijevoz i dovoljan kapacitet vozila javnog prijevoza s odgovarajućim cijenama u odnosu na cijene parkiranja. P+R objekti na rubovima gradskih zona snažno utječu na povećanu upotrebu javnog prijevoza putnika i doprinose nastojanjima promjene prijevoznih modova u smjeru gradskih središta.

Smanjivanje zagušenja u cestovnom prometu i rješavanje ostalih problema posredno i neposredno izazvanih parkiranjem (sigurnost, okoliš i dr.) korištenjem odgovarajuće politike parkiranja dat će najbolje rezultate u sredinama u kojima najveći udio prometa predstavlja onaj kojem je odredište unutar iste sredine. Ako je veći dio prometa prolaznog tipa tada će politika parkiranja imati znatno manji utjecaj na navedenu problematiku, a može čak imati i suprotno djelovanje, odnosno da privlačenje još većeg toka prometa kroz promatrano središte.

Cjelovita i učinkovita parkirališna politika kao neizostavni dio upravljanja parkiranjem i snažna potpora upravljanju zagušenjima treba biti usklađena s prostornim uređenjem i razvojnim planovima i baviti se svim aspektima parkiranja (uličnim i izvanuličnim parkiranjem, javnim i privatnim) uključujući određeni oblik naplate parkiranja i raspodjele parkirališnih mjesta, te biti povezana s politikom promoviranja pristupa urbanim središtima alternativnim modovima prijevoza. Grad Rim je kroz projekt Progress [77] postao primjer dobre prakse i pokazao kako upotrebom integrirane strategije doći do dobrih rezultata u nastojanju smanjivanja utjecaja zagušenja.

2.3. Sustavi za informiranje i upućivanje na parkirališna mjesta

Kruženje u svrhu traženja slobodnog parkirališnog mjesta značajan je čimbenik zagušenja prometa u gradskim središtima u vrijeme vršnih dnevnih prometnih opterećenja. Od 25 do 50 posto razdoblja najvećih prometnih gužvi otpada na promet vozila izazvan na taj način. Takvo je stanje veoma teško ispitati i potvrditi, no kada cijena i kvaliteta raspoloživih parkirališnih mjesta nisu jednako raspodijeljene duž prometno zagušenog gradskog središta, promet uzrokovan parkirališnom potražnjom može biti značajan [78]. Ovaj se problem ne odnosi samo na ulične parkirališne prostore već je uzrokovan i potražnjom odgovarajućeg parkirališnog mjesta unutar izvanuličnih parkirališta [79]. Studija koja je obuhvatila zračne luke u SAD-u pokazuje iskustva putnika čije je kašnjenje uslijed problema nastalih prilikom dolaska na odgovarajuća parkirališta itekako utjecala na kvalitetu njihovih putovanja [80].

Glavni cilj sustava za informiranje i upućivanje na parkirališna mjesta (*Parking Guidance and Information*, PGI) je smanjenje prometa uzrokovanog traženjem odgovarajućeg slobodnog parkirališnog mjesta u gradskim središtima i velikim parkiralištima. Na ulazima i izlazima parkirališta ili na pojedinačnim parkirališnim mjestima obično su instalirana osjetila ili uređaji za brojanje vozila kako bi se omogućilo prikupljanje podataka o broju zauzetih parkirališnih mjesta. Osjetila koja se koriste u ovu svrhu najčešće su induktivne petlje, infracrvena, ultrazvučna i magnetska osjetila, strojni vid, te laser [81], [109], [110], no u istu svrhu se koriste i mnoge druge tehnologije [82]–[94]. Prikupljeni podaci o raspoloživim parkirališnim mjestima šalju se žičnim ili bežičnim vezama u centralno računalo u svrhu procesiranja i odgovarajuće se informacije prenose vozačima putem statičkih ili promjenjivih prometnih znakova, mobilnih uređaja, radija, interneta ili telematičkih sustava u vozilu koji najčešće služe za navigaciju. Ove poruke obično sadrže poziciju raspoloživih parkirališnih mjesta i informacije o mogućim prometnim pravcima do istih, a mogu sadržavati i ostale korisne podatke poput zone, ukupnog broja raspoloživih parkirališnih mjesta na parkiralištu, cijene parkiranja i sl.

Sustavi za upućivanje na parkirališna mjesta i informiranje oblikovani su i implementirani s ciljem ostvarenja niza prednosti uključujući: skraćenje vremena putovanja, manje zagušenja na prometnicama i smanjenje nezadovoljstva vozača, manju potrošnju goriva i energije, smanjenje zagađenja zraka, smanjenje buke, povećanje prihoda od parkiranja i unaprjeđenje provedbe parkirališnih ograničenja [95].

Prvi je PGI sustav postavljen u gradu Aachen u Njemačkoj ranih 70-ih godina. Procjenjuje se da je do sredine 90-ih godina prošlog stoljeća postavljeno u gradove širom svijeta više od 100 inteligentnih sustava za upravljanje parkiralištima s najvećom koncentracijom u Europi

i Japanu [96]. Većina je ovih sustava pružala parkirališne informacije za gradska središta, no također ih se moglo pronaći u sklopu velikih parkirališta izvangradskih središta (npr. trgovačkim centrima i zračnim lukama). Brojni su gradovi implementirali PGI sustave i za rubno ulično parkiranje (npr. Southampton).

Posljednjih su se dvadesetak godina PGI sustavi postavili širom SAD-a. Tako su se pojavili u gradskim središtima u St. Paulu (Minnesota) i Pittsburghu (Pennsylvania) te na velikim parkirališnim prostorima u sklopu zračnih luka u Baltimoreu (Maryland), Houstonu (Texas), Orlando (Florida) i Minneapolis/St. Paulu (Minnesota).

2.3.1. PGI sustavi u gradskim središtima

U gradu Yokohama u Japanu PGI sustav pruža vozačima informacije o raspoloživosti slobodnih parkirališnih mjesta i upućuje ih na parkirališta. Obuhvaćeno je 16 parkirališta s više od 4000 parkirališnih mjesta. Sustav dijeli grad u četiri koncentrične zone. U prvoj zoni vozači ulaze na područje grada gdje se upoznaju s raspoloživim slobodnim parkirališnim mjestima putem detaljnih informacija na prometnim znakovima s promjenjivim sadržajem. Ulaskom u treću zonu prometni znakovi s promjenjivim sadržajem usmjeravaju vozače na parkirališta, te naposljetku na ulazu u parkirališne objekte pokazuju naziv objekta i ukupan broj slobodnih parkirališnih mjesta [108].

PGI sustav pod nazivom ROMANSE postavljen je 1992. u Southamptonu (Hampshire, UK). Ovaj je sustav uključivao 13 parkirališta i 26 ploča s promjenjivim sadržajem smještenim na glavnim prometnicama koje su prikazivale informacije u stvarnom vremenu o broju slobodnih parkirališnih mjesta. Sustav je trebalo proširiti i na ulična parkirališna mjesta uz izmjenu programskog dijela parkirališnih uređaja kako bi bili u mogućnosti komunicirati s centralnim računalom za obradu podataka [97].

U Europi je kasnih 70-ih godina, nakon prvih uspješno postavljenih PGI sustava, u Frankfurtu na Maini (Njemačka) izvorno instaliran PGI sustav kako bi navodio vozače na parkirališta sa slobodnim parkirališnim mjestima. Sustav je nadograđen 1992. godine pločama s promjenjivim sadržajem kako bi vozačima pružio više informacija o geografskim specifičnostima (npr. gradska zona, područje, parkiralište) u trenutku kada oni pristupaju svojim odredištima poput sustava primijenjenog u Yokohami [98], [108].

PGI sustav u gradu Ghent (Belgija) uključuje pet različitih procesnih faza: detekciju i procesiranje na lokalnoj razini, centralno procesiranje, kontrolu i provjeru, dinamičke znakove i prijenos podataka iz različitih komponenti sustava [99]. U svrhu prijenosa podataka parkirališnih osjetila do centralnog računala i slanja poruka s parkirališnim informacijama statičkim i dinamičnim promjenjivim prometnim oznakama koristi se televizijska distribucijska mreža. Sustav se neprekidno nadzire kako bi se otkrio svaki

potencijalni kvar u komunikaciji između parkirališta i centralne procesne jedinice. U slučaju prekinute komunikacije sustav predviđa raspoloživost parkirališnih mjesta uporabom povijesnih podataka [100].

U SAD-u se operativni test PGI sustava po prvi puta provodi u gradu St. Paul (Minnesota), no u međuvremenu se zbog zastarjele opreme obustavlja i pokreće postupak za nadogradnju i zamjenu dijela sustava. Namijenjen prvenstveno posjetiocima i turistima sustav je povezivao 10 parkirališta (7 garaža i 3 otvorena parkirališna prostora u javnom i privatnom vlasništvu) s centralnim računalom. Podaci s parkirališta su se u stvarnom vremenu obrađivali na centralnom računalu i parkirališne su se informacije prikazivale na LED zaslonima koji su se nalazili na svim kritičnim gradskim raskrižjima [100], [108].

U Pittsburghu (Pennsylvania) je implementiran PGI sustav koji je vozače navodio do parkirališta i posebnih znamenitosti. Većina prometnih znakova sustava bila je statičkog karaktera osim onih koji su se nalazili na parkiralištima u sklopu gradskog stadiona [106], [108].

Također, predložena je i planirana ugradnja PGI sustava s odgovarajućim prometnim znakovima koji bi prikazivali dinamičke poruke i pružali informacije o slobodnim parkirališnim mjestima u stvarnom vremenu u San Joseu (California) i New York Cityju [101], [107].

U novije se vrijeme razvijaju i implementiraju različite inačice sustava za upućivanje na raspoloživa parkirališna mjesta širom svijeta. Postojeći se sustavi nadograđuju novim mogućnostima ili se u cijelosti zamjenjuju, te svoju primjenu nalaze kod sve šireg broja korisnika.

2.3.2. PGI sustavi u sklopu velikih parkirališta

Jedan od vodećih primjera PGI sustava na velikim parkiralištima izgrađen je u gradu Bristol u Engleskoj. Nekoliko parkirališnih struktura s ukupno 2.645 parkirališnih mjesta opremljeno je PGI sustavom za detekciju i upućivanje vozila do slobodnog parkirališnog mjesta. Sustav je koristio infracrvena osjetila za detekciju raspoloživih parkirališnih mjesta, prenosio informacije do centralnog računala, prikazivao broj slobodnih parkirališnih mjesta na svakoj strukturalnoj razini i navodio vozila do njih. Sustav je bio u mogućnosti predviđati parkirališnu potražnju u određenom dijelu dana na osnovi povijesti parkiranja na parkirališnom prostoru. Rezultat toga je sposobnost sustava da pravovremeno predvidi trenutak popunjenja parkirališta ili njegovog segmenta te preusmjeri po potrebi vozila na druga raspoloživa parkirališta [108].

Drugi takav primjer je parkiralište s više razina koje djeluje u sklopu zračne luke Blagnac u Toulouseu (Francuska). Svako parkirališno mjesto nadgledano je ultrazvučnim osjetilom i LED svjetla navode vozače do raspoloživih parkirališnih mjesta. Sličan sustav instaliran je i na parkiralište trgovačkog centra u Istambul (Turska) [108].

Puno napredniji sustav implementiran je u međunarodnoj zračnoj luci Baltimore-Washington u SAD [100]. Ovaj sustav trenutno koristi ultrazvučne senzore u svakom parkirališnom mjestu parkirališta za praćenje zauzetosti parkirališnog prostora. Svijetleće elektroničke oznake navode vozača do raspoloživog parkirališnog mjesta, prikazuju ukupan broj raspoloživih parkirališnih mjesta po prolazu i status zauzeća svakog pojedinog mjesta [100], [108].

Druga dva parkirališta u SAD koriste PGI sustave koji prate broj raspoloživih parkirališnih mjesta na pojedinim razinama parkirališta, a ne svako pojedino raspoloživo parkirališno mjesto. U međunarodnoj zračnoj luci St. Paul prate se ulazna i izlazna razina parkirališta Humphrey, te se uz pomoć svijetlećih signala na stropu vozilima prikazuje raspoloživost parkirališnih mjesta na svakoj razini [108], dok se u međunarodnoj zračnoj luci George Bush koristi sustav žica ugrađen u infrastrukturu garaže (sedam razina sa 6.500 mjesta) za praćenje raspoloživosti parkirališnih mjesta, drvene rampe za zatvaranje popunjenih razina i digitalni zaslone za upućivanje vozila do razine sa slobodnim parkirališnim mjestima [111].

Usprkos relativno velikom broju PGI sustava instaliranih u SAD, Europi i Japanu postoji tek nekoliko studija koje vrednuju njihove učinke [102] i većina se tih studija fokusira na dinamičke sustave upućivanja na raspoloživa parkirališna mjesta u gradskim središtima. Nažalost, provedene studije radije teže opisnim statističkim metodama nego puno složenijim tehnikama s više varijabli [87].

Rezultati istraživanja navedenih studija i istraživanja koja su provedena u sklopu razmatranja inteligentnih sustava za upućivanje vozila na slobodna parkirališna mjesta [103], [104], [105], pokazuju da se upotrebom PGI sustava vidljivo doprinosi smanjenju vremena putovanja, a samim time i smanjenju potrošnje goriva i emisije štetnih plinova te ostalih negativnih učinaka.

2.3.3. Moderni PGI sustavi

Danas se na tržištu mogu pronaći različita rješenja i pristupi u realizaciji sustava za upućivanje vozila na parkiranje. U.S. Department of Transportation pokreće program pod nazivom *Active Transportation and Demand Management (ATDM)* unutar kojeg se nalazi i *Active Parking Management* program čija je uloga dinamičko upravljanje parkirališnim objektima u regiji kako bi se povećala učinkovitost i iskoristivost na način utjecaja na izbor vremena i modova putovanja, te naposljetku i odgovarajućeg parkirališnog objekta. Cilj

programa je smanjiti zagušenja, povećati sigurnost i infrastrukturna ulaganja. ATDM pristup uključuje dinamičko određivanje cijene parkiranja, dinamičko rezerviranje parkirališnih mjesta, dinamičko pronalaženje puta i dinamičko popunjavanje parkirališnih kapaciteta.

Osnovna komponenta aktivnog upravljanja parkiranjem je informacija. Informacija koju treba pružiti korisniku kako bi mogao donijeti odluku u vezi s parkiranjem mora biti jasna, precizna, relevantna, detaljna i stvarnovremenska te prenesena na više različitih načina i u više različitih formata. To uključuje i tradicionalne statičke prometne znakove, prometne znakove s promjenjivim sadržajem, internet, mobitele, pametne mobitele i slične mobilne uređaje, navigacijske uređaje i sl. Buduća bi rješenja trebala unaprijediti postojeća i uključivati nove napredne tehnologije, te se primijeniti i na ulične i izvanulične parkirališne prostore.

Primjeri dobre prakse koji su nastali kao rezultat prethodno navedenog programa su:

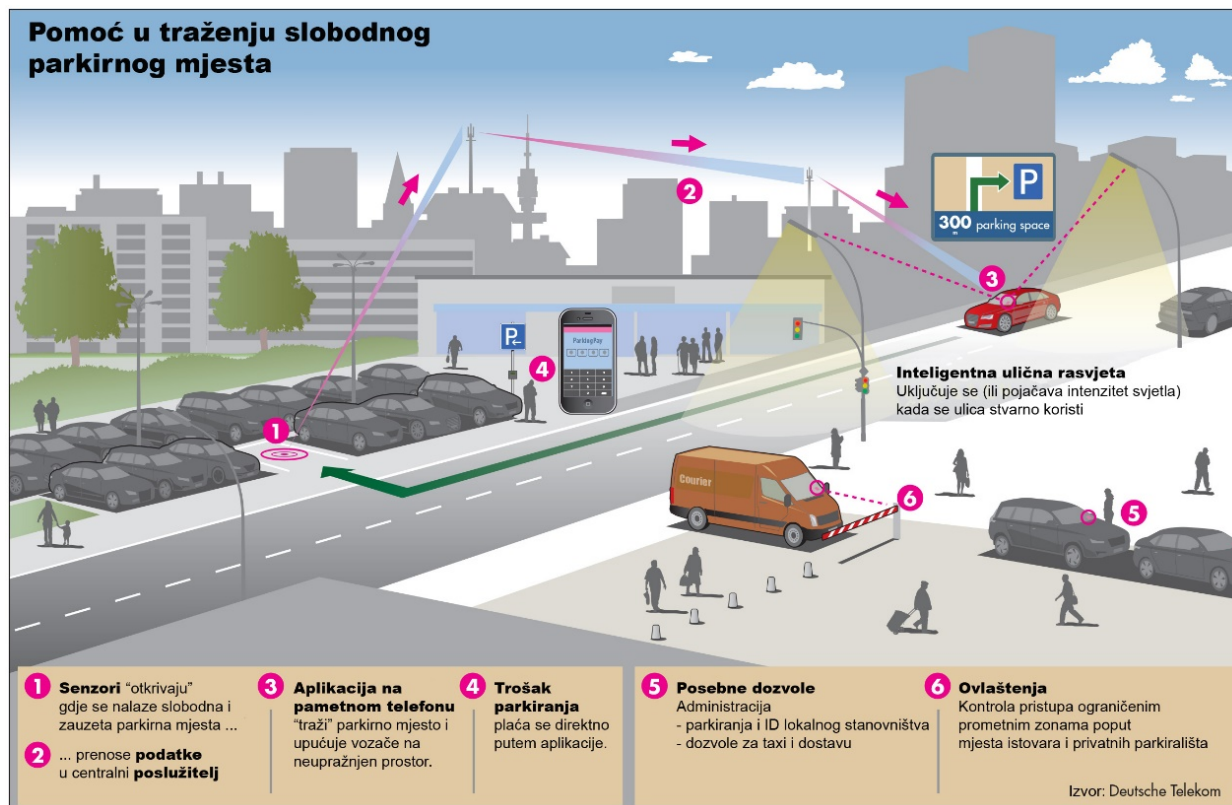
- **SFpark**
(San Francisco, CA, <http://sfpark.org>)
- **PARK Smart**
(New York, NY, <http://www.nyc.gov/html/dot/html/motorist/parksmart.shtml>)
- **ExpressPark™**
(Los Angeles, CA, <http://expresspark.lacity.org>)
- **Capri**
(Stanford, CA, <https://stanfordcapri.org>) i
- **QuickPark**
(San Diego, CA, <http://compass.511sd.com/QuickPark/Default.aspx>).

Njemački mobilni operater *Deutsche Telekom* pokrenuo je šestomjesečni pilot-projekt čiji je zadatak bio usmjeren na uvođenje inteligentnog sustava za upućivanje na parkiranje u gradu *Pisi* (Italija) kako bi se pomoglo vozačima motornih vozila i turistima pronaći slobodno parkirališno mjesto brzo i lako.

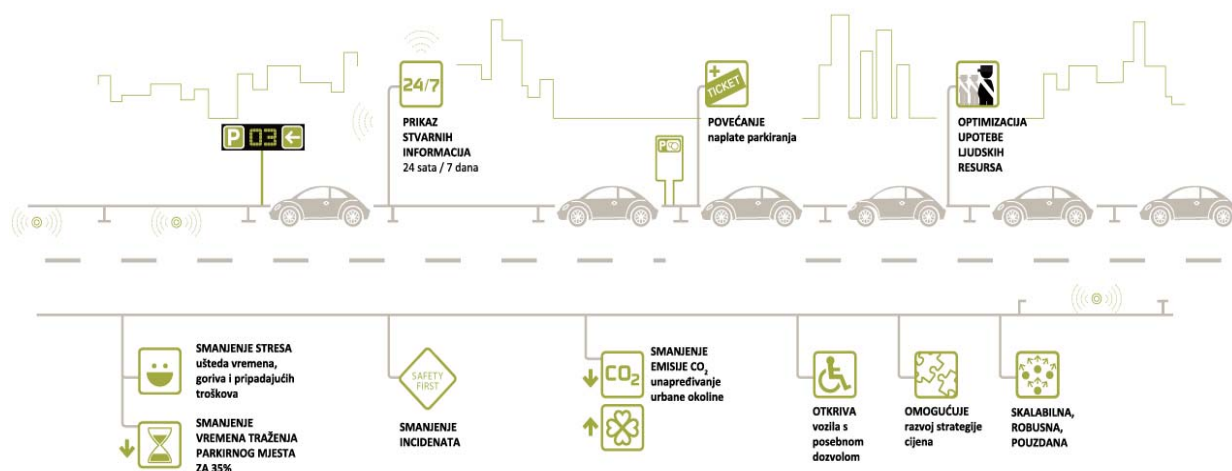
Deutsche Telekom i partnerska kompanija Kiunsys u suradnji s lokalnim vlastima ovoga talijanskog grada ugradili su senzore u svako parkirališno mjesto na području pod nazivom Piazza Carrara. Ugrađeni uređaj prikuplja informacije i prosljeđuje ih putem mobilne mreže u gradsku poslužiteljsku infrastrukturu prije prikazivanja na interaktivnim panelima za upućivanje vozača na slobodno mjesto ili unutar postojeće gradske aplikacije Tap&Park.

Sustav omogućava gradskim dužnosnicima analiziranje povijesnih podataka putem velikog podatkovnog servisa, pomaže pri izbjegavanju prometnih gužvi i smanjuje emisiju štetnih plinova u gradu (Slika 2.).

Rješenje za pametne gradove pod nazivom *Fastprk* (www.fastprk.com) proizvelo je poduzeće Worldsensing čija je osnovna djelatnost proizvodnja senzora za specifične potrebe. Jedno od najnaprednijih i najpouzdanijih sustava ovoga tipa za upućivanje na parkiranje omogućava informiranje korisnika putem uličnih panela ili mobilnih uređaja. *Fastprk* radi u stvarnom vremenu, koristi magnetske senzore i može biti spojen na bilo koji sustav naplate (Slika 3.).



Slika 2. Rješenje telekomunikacijskog operatora u talijanskom gradu Pisi



Slika 3. Prikaz mogućnosti rješenja za upućivanje na parkiranje pod nazivom *Fastprk*

Poduzeće *ParkHelp* (www.parkhelp.com) specijaliziralo se za izradu parkirališnih rješenja za općine. Njihovi inteligentni sustavi za upućivanje vozila na parkiranje pružaju stvarnovremenske informacije o slobodnim parkirališnim mjestima te brzo i učinkovito upućuju korisnike do slobodnih mjesta. Sustav odlikuju robusni senzori otporni na incidente, dinamička signalizacija, mobilna aplikacija, centralna upravljačka aplikacija, a po potrebi se ugrađuju i uređaji koji putem signalnih stupova signaliziraju korisniku kada istječe zakupljeni period parkiranja.

Slična rješenja nude: švicarsko poduzeće *TinyNode* (www.tinynode.com), njemačka poduzeća *MSR-Traffic* (www.msr-traffic.de) i *Mobilisis* (mobilisis.eu), globalna korporacija *HUB Parking Technology* (www.hubparking.com), američki *IPS Group Inc.* (www.ipsgroupinc.com), francuski *Parkeon* (www.parkeon.com), grčka *Moviva* (www.moviva.gr), nizozemski *Nedap* (www.nedap.com), belgijski *Pulsar Consulting SA* (www.parking-guidance.com), austrijski *Swarco AG* (www.swarco.com), azijski *Rosim* (www.rosimits.com) i *InnoTek* (www.innotek-co.com), te mnogi drugi².

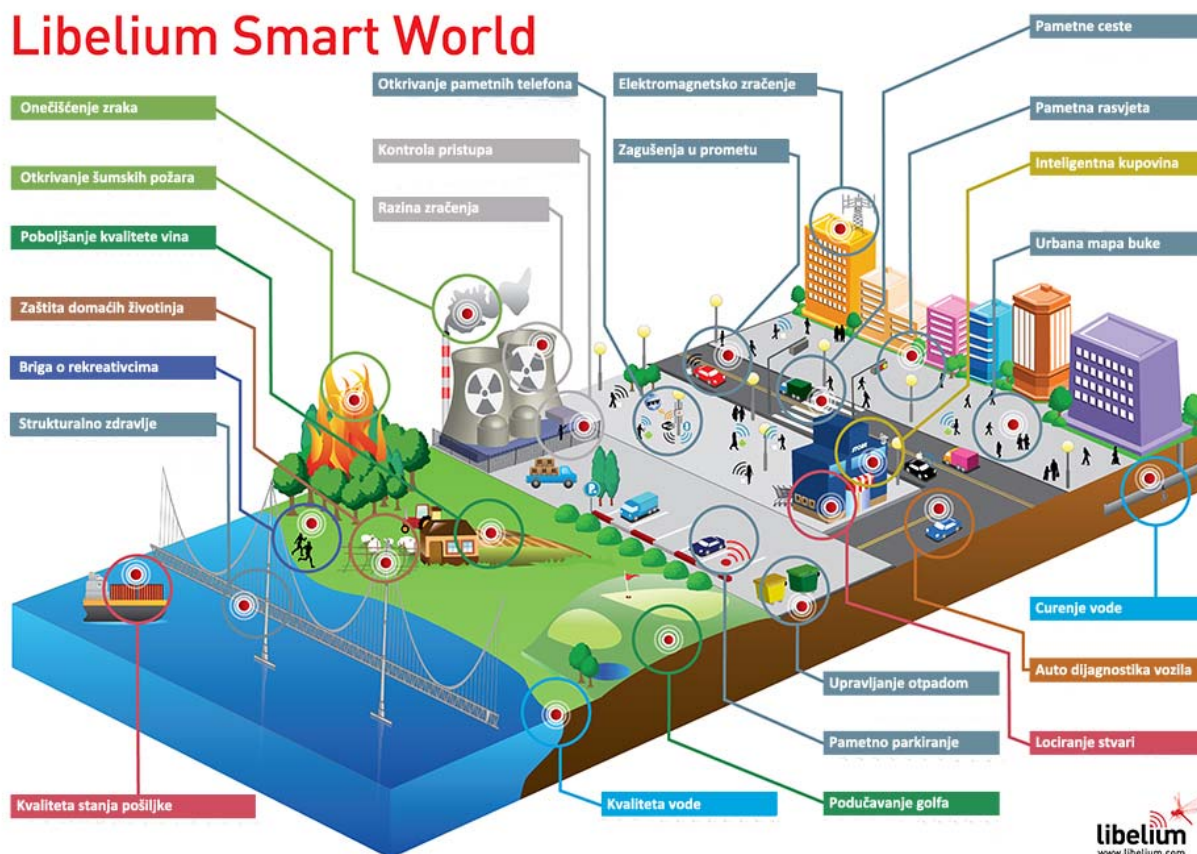
Posebno se svojim inovacijama i širokim područjem primjene u domeni pametnih gradova ističe španjolski proizvođač bežične senzorske opreme *Libelium* (www.libelium.com). Na slici 4. prikazan je cijeli spektar mogućnosti primjene različitih senzora koji uključuju i pametno parkiranje te sprječavanje prometnih zagušenja.

Uz cjelovita programske-sklupovske rješenja za upućivanje vozila na parkiranje koja se mogu naći na tržištu, posljednjih desetak godina razvijen je cijeli niz različitih mobilnih aplikacija za upravljanje parkirališnim mjestima.

U Madridu i Barceloni u Španjolskoj pojavio se sustav za upravljanje parkiranjem koji ostvaruje 52 % uštede na naknadama za parkiranje i u prosjeku oko 20 minuta na traženju slobodnog parkirališnog mjesta. Poduzeće *WeSmartpark* spoznalo je da u Barceloni svaki dan 375.000 vozila doputuje u grad, a količina parkirališnih mjesta je 279.000. U želji da pomognu riješiti ovaj problem poduzeće je osmislilo sustav koji će dozvoliti vlasnicima privatnih parkirališnih mjesta iznajmljivanje u razdobljima kada su ona tijekom dana prazna i ne koriste se. Na ovaj se način udvostručava broj parkirališnih mjesta i znatno povećava parkirališna ponuda u gradu što je ubrzo prepoznato i izvan granica Španjolske, te su i druge države prihvatile dio ideja koje su nastale iz ovog pristupa.

² Na Parking Network internetskim stranicama (www.parking-net.com), koje predstavljaju relevantan izvor informacija u svezi s parkirališnom industrijom, redovito se objavljuju novosti o novim postignućima.

Libelium Smart World



Slika 4. Koncept pametnog svijeta prema vizijama razvojnog tima poduzeća Libelium

Korisnik servisa treba rezervirati jedno parkirališno mjesto koje je vlasnik postavio na internet. Pomoću kartice koja se može „napuniti“ novcem osiguran je pristup rezerviranom parkirališnom mjestu. *WeSmartpark* sustav detektira vozilo i ako je rezervacija ispravna automatski otvara vrata. Rezervaciju je moguće provesti putem računala ili mobilne aplikacije pod nazivom *Aparca Ya* (parkiraj sad) koja pruža informaciju vozaču o raspoloživim parkirališnim mjestima blizu njegovog željenog odredišta. Rezervirati se može prije dolaska u grad ili u stvarnom vremenu tijekom traženja slobodnog parkirališnog mjesta. Zahvaljujući ovom novom sustavu mobilnost ljudi u gradu puno je učinkovitija.

Mobilna aplikacija *JustPark* (www.justpark.com) podrijetlom iz UK, funkcionira isto kao i aplikacija *WeSmartpark*, koristi je čak 180.000 ljudi u UK i 250.000 širom svijeta.

U Barceloni se uz mobilnu aplikaciju *WeSmartpark* koja koristi privatna parkirališna mjesta, koristi i aplikacija pod nazivom *apparkB*. Nakon što su gradske vlasti u tom gradu odlučile dozvoliti naplatu parkiranja putem mobilnih uređaja za svoju plavu i zelenu zonu građani su mogli koristiti mobilne uređaje kao alternativu plaćanja putem parkirališnih uređaja. Posebna pogodnost koja se nudila građanima bila je naplata točno onog vremena koje je vozilo provelo na parkiralištu za razliku od sustava naplate putem parkirališnih aparata.

Također, ako bi korisnik zaboravio gdje je parkirao vozilo, aplikacija bi ga navodila uz pomoć geolokacijskih usluga.


Aplikaciju je u cijelosti financirao grad tako da je za korisnike besplatna, a moguće ju je koristiti i na iOS i Android uređajima. Da bi se aplikacija mogla koristiti nužno je izvršiti registraciju koja će upamtiti ID osobe, broj kreditne kartice i registarsku oznaku vozila. Prilikom korištenja, aplikacija obavještava korisnika kada mu ističe rezervacija, a u slučaju da mobilni uređaj ostane bez baterije najam se može prekinuti upotrebom običnog telefona. Korisnik je prilikom upotrebe aplikacije upoznat s maksimalnim dozvoljenim trajanjem parkiranja u određenoj zoni i cijeni koja je na snazi u zahtijevanom vremenu. Uz privatnu registraciju svaki korisnik može imati i drugi korporativni račun koji omogućava da više korisnika koristi isto vozilo. Poduzeća imaju potpuni nadzor nad troškovima parkiranja u bilo kojem trenutku. Gradski službenici mogu provjeravati parkirana vozila očitavanjem registarskih oznaka upotrebom dlanovnika i na taj način spriječiti nelegalno korištenje parkirališta.

Aplikacija pod nazivom *PayPark* koja se koristi u Madridu i Gironi radi na isti način s time da sav prihod ostvaren tim putem odlazi na osobe s invaliditetom. U gradu Ottawi (Kanada) koristi se aplikacija kojoj se može pristupiti putem interneta ili mobilnim uređajima i koja se u osnovi razlikuje od aplikacije *apparkB* po tome što ne geolocira svoje korisnike. Aplikaciji je potrebno proslijediti broj s uređaja za naplatu parkiranja i s računa će se skinuti određen iznos cijene parkiranja uvećan za 25 centi. Aplikacija se naziva *PayByPhone Parking*. Ova aplikacija se koristi i u centru Londona te u američkom gradu Seattle, ali s drugom cijenom transakcije.

Na tržištu se mogu pronaći i mnoge druge mobilne aplikacije za upravljanje parkirališnim mjestima poput *Parkopedie* koja omogućava korisnicima razmjenu informacija o parkiralištima s ciljem pronalaženja najadekvatnijeg parkirališnog mjesta, *WhereiPark* koja traži parkirališna mjesta blizu odredišta, uspoređuje cijene i naposljetku zakupljuje mjesto, *Parking Pande*, *Sofortparken* itd. Nešto drugačiji pristup koriste mobilne aplikacije *Monkey Parking*, *Sweetch* i *ParkModo*. Vozači registriraju mjesto gdje su parkirali i kada odluče napustiti lokaciju prepuštaju mjesto drugom zainteresiranom vozaču na istom području. Drugi vozač koji dolazi na parkirališno mjesto plaća prvom, a aplikacija obračunava troškove usluge. Na taj način vozači ostvaruju uštedu jer ne plaćaju za vrijeme koje nisu koristili parkiralište, odnosno parkiranje se ne naplaćuje dva puta.

Sva navedena pametna parkirališna rješenja, bez obzira radi li se samo o mobilnim aplikacijama koje upravljaju parkirališnim mjestima ili o cjelovitim inteligentnim parkirnim sustavima, u određenoj mjeri umanjuju negativne učinke koji su nastali uslijed procesa parkiranja. Ovu činjenicu vjerojatno najbolje potvrđuje istraživanje koje je u

SAD-u proveo Međunarodni institut za parkiranje (International Parking Institute), a čiji su rezultati prikazani na slici 5.



Slika 5. Rezultati istraživanja Međunarodnog instituta za parkiranje

Parkirališna je industrija u stalnom razvoju zahvaljujući novim tehnologijama, inovativnim aplikacijama i znanju te stručnosti profesionalaca na području parkiranja. Izvješće Međunarodnog parking instituta, kojeg čine parkirališna udruženja na području SAD-a, stavlja naglasak na nekoliko ključnih nadolazećih trendova [112]:

- **Održivost** – objekti namijenjeni za parkiranje postaju „zeleni“ uporabom energetski učinkovite fluorescentne rasvjete koja duže svijetli i pruža više sigurnosti. Potrošnja energije u objektima za parkiranje se smanjuje uporabom brojača, fotoćelija i prigušenog osvjetljenja. Većina novih objekata gradi se prema zahtjevnim LEED³ standardima što uključuje primjenu reciklažnih sustava kao što su sustavi za recikliranje kišnice, korištenje recikliranih materijala u konstrukciji i uporabu obnovljivih izvora energije poput solarnih ploča, vjetroelektrana, bioloških goriva i vodikove gorive ćelije. Objekti također imaju razvijene sustave za gospodarenje otpadom i njegovo odlaganje.

³ Leadership in Energy and Environmental Design

- Uporaba mobilnih aplikacija – ekspanzija novih aplikacija za pametne telefone i mobilne uređaje pruža mogućnosti pronalaska, rezervacije i plaćanja parkiranja.
- Poboljšano upravljanje prometom – osnaživanje prometnih tokova uporabom bežičnih senzora koji ukazuju na raspoloživost prostora u parkirališnim objektima i uređajima za navigaciju u vozilu koji prikazuju lokaciju parkirališta.
- Kontrola pristupa parkiralištu – upotreba kamera i specifičnih programskih rješenja za prepoznavanje registracijskih oznaka u svrhu utvrđivanja ovlasti prilikom pristupa parkirališnom objektu.
- E-plaćanje – parkirališna se industrija sve više odmiče od tradicionalnog načina plaćanja novčanicama i pruža mogućnost plaćanja na različite načine.
- Postaje za punjenje električnih vozila – uslijed povećanja broja električnih vozila očekuje se da parkirališta imaju stanicu za punjenje.
- Integracija parkiranja s planiranjem – parkirališni su operateri prepoznati kao osobe koje svojim specijalističkim znanjima mogu značajno pridonijeti urbanim projektima. Potrebno ih je uključiti u timove s arhitektima, inženjerima, programerima i planerima.

Na slici 6. prikazani su trendovi koji imaju najveći utjecaj na parkirališnu industriju, a na slici 7. oni koji najviše mogu utjecati na poboljšanje održivosti.

Međunarodni institut za parkiranje je u svojoj publikaciji [112] objavio da će do 2020. godine na području Amerike znatno porasti broj parkirališnih mjesta opremljenih senzorima što će otvoriti niz različitih mogućnosti za pametne parkirne sustave.

Europsko udruženje za parkiranje (*European Parking Association*, EPA) ukazuje na potrebu razvijanja svijesti o činjenici da ne postoje besplatna parkirališna mjesta, te da vozači uopće nisu svjesni potrebe plaćanja ukupnih troškova parkirališnih mjesta. Tu cijenu u cijelosti ne plaćaju vozači, ali je subvencionirana od strane poreznih obveznika u Europi u iznosu od 300 eura po poreznom obvezniku godišnje [114].



Slika 6. Prikaz trendova koji imaju najveći utjecaj na parkirališnu industriju [113]



Slika 7. Prikaz trendova koji imaju najveći potencijal za poboljšanje održivosti [113]

S ciljem osiguravanja kvalitete i sigurnosti na području europske mobilne infrastrukture 2013. godine provedeno je testiranje u sklopu *EuroTest* programa na 60 garaža širom Europe⁴ koje je između ostaloga obuhvaćalo i sustave za dinamičko upućivanje na parkiranje. Od ukupnog broja testiranih garaža njih čak oko 25 % nema implementiran nikakav sustav za navođenje, jedna trećina ima sustave sa signalizacijom koja nije optimalna ili uopće nije u funkciji, više od pola testiranih garaža nema numerički označena parkirališna mjesta kako bi se pomoglo vozačima jednostavnije pronaći svoja vozila, čak više od dvije trećine nema označene pješačke staze, 70 % garaža nema telefone za hitne slučajeve, od ukupnog broja parkirališnih mjesta 19 % su minimalne širine od 3 m i jedna četvrtina garaža je loše održavana.

Evidentni i mjerljivi problemi u svezi s parkiranjem koji se prije svega odnose na zagušenja, onečišćenje okoliša i sigurnost, opravdaju relativno visoka ulaganja u inteligentne parkirne sustave. Racionalno upravljanje parkirališnim prostorima i kvalitetno postavljene strategije i politike parkiranja mogu znatno djelovati na kvalitetu života u lokalnim zajednicama i zadovoljstvo korisnika usluga. Navedeni sustavi kao podskupina inteligentnih transportnih sustava postaju sastavni dijelovi vizije pametnih gradova što im prije svega omogućuje brz tehnološki razvitak. Kao prepoznatljiv dio koncepta interneta stvari, inteligentni parkirni sustavi ubrzo će biti neizostavni dio novih infrastrukturnih projekata većih gradskih središta.

⁴ Testiranje je provodio konzorcij sastavljen od članova europskih automobilskih klubova, pod pokroviteljstvom udruženja FIA (*Fédération Internationale de l'Automobile*) iz Brisela koje predstavlja preko 34 milijuna mobilnih europskih korisnika.

3. NAPREDNI SUSTAVI ZA INFORMIRANJE PUTNIKA

Sastavni dio inteligentnih transportnih sustava su i napredni sustavi za informiranje putnika (*Advanced traveler information systems*, ATIS) koji korisnicima pružaju više prijevoznih mogućnosti i povećavaju učinkovitost putovanja. Putnici koji putuju na kraćim ili dužim relacijama imaju potrebu za informiranjem o stanju na cesti, vremenskim uvjetima, dužini i trajanju putovanja, te o potencijalnim područjima od interesa koji se mogu nalaziti duž predviđene rute. Pri promjeni moda prijevoza i čekanju na nastavak putovanja (autobusom, vlakom, brodom, zrakoplovom) informacije potrebne putnicima poput voznih redova i cijena prijevoznih sredstava već su spremne za distribuciju zainteresiranim korisnicima. Putnici koji imaju prethodna saznanja o prometnim zagušenjima, incidentima na prometnicama i mogućim zastojevima umanjit će stresnost svojeg putovanja, iako u potpunosti ne mogu izbjeći sve negativne čimbenike. Nadalje, taksi prijevoznici i vozači kamiona imaju direktne koristi od uporabe putničkih informacija koje im omogućuju izbjegavanje neisplativih zastoja u prometu, a time i veću produktivnost i isplativost poslovanja.

Informacije o putovanju mogu se koristiti prije ili tijekom putovanja pa se stoga mogu i podijeliti na preputne i putne informacije. Preputne informacije omogućavaju korisniku planiranje putovanja, izbor načina (moda) putovanja, te prepoznavanje i odabir mjesta za zaustavljanje. No, uvjeti su putovanja dinamičkog karaktera i mogu se promijeniti i nakon polaska pa je stoga korisno putnicima omogućiti pristup odgovarajućim informacijama i tijekom putovanja, odnosno u prijevoznom sredstvu i na mjestima zaustavljanja. Takve se informacije nazivaju putne informacije.

ATIS za razliku od svojih tehnološki znatno slabije razvijenih prethodnika na drugačiji način prikuplja, obrađuje i isporučuje podatke. U ovim se naprednim sustavima informacije spremaju u računalne baze podataka (ili u računalne oblake koji su danas gotovo nezaobilazni dio uslužno orijentirane arhitekture) i uz moderne računalne i komunikacijske tehnologije mogu biti preuzete i isporučene u bilo koje vrijeme i na bilo kojem mjestu. Brz razvoj i sve šira primjena novih tehnoloških postignuća predstavljaju osnovu za unaprjeđivanje. Ona se prije svega očituje u povećanju procesorske snage i brzine, digitalizaciji svih oblika podataka, novim pristupima u bežičnom prijenosu podataka, mogućnostima kvalitetnijeg prepoznavanja i sintetiziranja govora, odnosno stvaranju novih ljudsko-strojnih, odnosno ljudsko-računalnih sučelja s kvalitetnim prepoznavanjem govora, dostupnosti preciznijim podacima satelitskih globalnih

položajnih sustava (*Global Positioning System*, GPS), stupnju minijaturizacije i inovacijama na području uređaja za napajanje i kemijskih izvora energije.

Telekomunikacijski podsustavi, koji uključuju glasovne, podatkovne ili videoprijenose žičnim i bežičnim mrežama, omogućuju zainteresiranim putnicima pristup ATIS bazama podataka putem cijelog niza tehnološki sve naprednijih i razvijenijih tipova uređaja poput mobilnih telefona, kabelaške televizije, dlanovnika i prijenosnih računala, te jedinica u vozilu. Većina ATIS procesa je gotovo u cijelosti automatizirana i na zahtjev poslužuje putnike bez potrebe za ljudskom intervencijom. Preputne informacije distribuiraju se korisnicima prvenstveno putem informacijskih servisa na fiksnim lokacijama poput infokioska smještenim na područjima od interesa (trgovačkim centrima ili drugim odgovarajućim mjestima s velikim prometom pješaka), mrežnih stranica kojima se može pristupiti s bilo kojeg mjesta gdje postoji internetska veza i servisi fiksne telefonije. Distribucija putnih informacija prvenstveno se provodi bežičnim putem uporabom mobilnih telefona, prijenosnih računala i jedinica u vozilu.

Osnovni je cilj navedenih sustava pružanje informacija koje trebaju zadovoljiti potrebe organizacija ili pojedinaca. Neovisno o tome radi li se o uobičajenim putnicima, poslovnim putnicima, turistima, osobama koje upravljaju komercijalnim vozilima na kraćim ili dužim relacijama, sustav treba biti sposoban pružiti odgovore na razna pitanja kao što su: gdje se nalaze prometna zagušenja, koje se autobusne i željezničke rute mogu koristiti, koje prometnice imaju ograničenja za teška teretna motorna vozila i vozila s prikolicom, itd. Društva i agencije za javni prijevoz na ATIS gledaju kao na alat za upravljanje prijevozom koji im pomaže u postizanju ciljeva prijevozne politike smanjivanjem zagušenja i neposrednim povećavanjem broj vozila u tranzitu. Društva i agencije za javni prijevoz se nadaju da će osiguravajući kvalitetne i stvarnovremenske informacije o prometnoj mreži putem ovakvih sustava utjecati na ponašanje putnika, te na taj način doprinosti cjelokupnoj prometnoj situaciji na odnosnom području. S druge strane, to je i želja poslovnih subjekata uključenih u razvoj i izgradnju sustava kako bi opravdali relativno visoku cijenu.

Identifikacija mogućih područja primjene i ciljeva sustava jedan je od najvažnijih zadataka timova koji rade na planiranju, no treba imati na umu da se sustav ne bi trebao usredotočiti na dio prometne problematike i određene modove prijevoza već osigurati širinu i dostupnost informacija. Također, širenje slobodnih i besplatnih informacija ne bi smjelo doprinosti uništavanju komercijalnih servisa.

Tablica 4. Sadržaj koji ATIS mogu prikazivati

Statičke informacije (unaprijed poznate, mala učestalost promjene)	planirane aktivnosti izgradnje i održavanja
	posebni događaji (parade, proslave, obilježavanja, sportski, kulturni i drugi događaji)
	načini plaćanja i troškovi cestarine
	troškovi vozila u tranzitu, rute, čekanja, itd.
	veze s drugim modovima prijevoza
	propisi za komercijalna vozila (npr. za opasan teret, teška teretna motorna vozila i vozila s prikolicom)
	cijena i lokacija parkirališnih mjesta
	poslovna ponuda (npr. hoteli, benzinske postaje)
	turistička odredišta
	navigacijske upute
Dinamičke informacije (stvarnovremenske, visoka učestalost promjene)	uvjeti na cestama, uključujući informacije o nezgodama i zagušenjima
	alternativne rute
	vremenski uvjeti na prometnicama poput snijega, leda i magle
	raspored tranzitnog prijevoza
	raspoloživost parkirališnih mjesta
	vrijeme putovanja
	informacije o autobusnim, željezničkim i trajektnim odredištima

Izvor: Prilagodio autor na osnovi „Developing Traveler Information Systems Using the National ITS Architecture“, U. S. Department of Transportation, Washington, 1998., pp. 2-4

3.1. Napredna osjetila u cestovnom prometu

Tehnologije koje će u nastavku biti opisane rijetko se koriste samostalno već su neizostavni dijelovi sustava i podsustava u sklopu različitih ITS rješenja. Izraz "osjetilo" podrazumijeva sklopovlje i ugrađenu programsku podršku kojima se otkriva prisustvo vozila na prometnici i pretvaraju dobivene informacije u podatke o prometnom toku. Parametri prometnog toka koji se obično koriste u ITS aplikacijama uključuju volumen, zauzetost prometnih traka, potražnju, prostorno napredovanje, propusnost, trenutnu i prosječnu brzinu vozila, gustoću, kašnjenje, zaustavljanje, podatke ishodište-odredište, okretni moment i funkcionalnu konfiguraciju [115].

Algoritmi za obradu podataka mogu se nalaziti u sklopovlju osjetila, infrastrukturnom elementu ili centru za upravljanje prometom. Algoritmi koji se nalaze u modulu osjetila obično od primljenog signala generiraju sirove podatke koji najčešće sadrže informaciju o

prisustvu vozila i broju. Oni mogu pružiti i obrađene podatke poput napredovanja, brzine pojedinog vozila i prosječne vrijednosti različitih parametara prometnog toka. Algoritmi u cestovnom kontroleru pružaju prosječne vremenske podatke poput zauzetosti traka, broja vozila u određenim vremenskim razdobljima, broja zaustavljanja, propusnosti i reda čekanja. Ostatak obrade podataka provodi se u centrima za upravljanje prometom gdje se podaci dobiveni s prometnica spajaju s informacijama dobivenim iz ostalih izvora.

U kooperativnim se sustavima informacije dobivene od osjetila mogu obrađivati i u vozilu kako bi se spriječilo moguće kašnjenje uzrokovano putovanjem informacije do upravljačkog centra i zatim do vozila te osiguralo stvarnovremensko obilježje. Naravno, takva osjetila moraju biti opremljena uređajima za bežičnu komunikaciju.

3.1.1. Induktivne petlje

Induktivne petlje (*Inductive loop detectors*, ILD) su zbog svoje široke primjene najčešće korišteno osjetilo u sustavima za upravljanje prometom. Sastoje se od jednog ili više namota izolirane žice koja formira kružnicu promjera 6 stopa ili kvadrat iste širine. Ugrađuju se plitko u strukturu prometnice i spajaju s odgovarajućim električnim uređajem i kontrolerom koji se nalaze u ormariću pored prometnice. Žičana petlja se pobuđuje signalom od 10 do 50 KHz čime se oblikuje lokalno magnetsko polje iznad prometnice. U trenutku kada se metalno vozilo zaustavi na odnosnom prometnom segmentu ili prođe preko njega indukcija petlje se smanjuje što pak dovodi do povećanja frekvencije osciliranja. Električni uređaj tada šalje impuls kontroleru ukazujući na prisustvo ili prolazak vozila. Novije inačice induktivnih petlji koriste više frekvencije kako bi otkrile određene metalne dijelove vozila i tako omogućile njihovo razvrstavanje. Posebno se može istaknuti njihova upotreba na ulazima i izlazima iz garažnih objekata, a jedan od vodećih nedostataka im je komplicirana naknadna ugradnja u prometnice.

3.1.2. Magnetska osjetila

Magnetska osjetila mjere poremećaje Zemljinog magnetskog polja uzrokovane prisustvom metalnih dijelova vozila. Često se koriste umjesto induktivnih petlji gdje njihova primjena nije moguća (npr. na mostovima ili ojačanim kolnicima). Dva se tipa osjetila magnetskog polja koriste za mjerenje parametara prometnog toka. Prvi se tip naziva dvo-osni vektor magnetometar (*fluxgate magnetometer*) i otkriva promjene u horizontalnoj i vertikalnoj komponenti Zemljinog magnetskog polja. Dva su načina rada ovoga tipa magnetometra. U prvom, impulsnom načinu rada magnetometar može brojati vozila koja prolaze prometnicom (isprekidani signal na izlazu), a u drugom može otkrivati njihovo prisustvo (kontinuirani izlazni signal dok je vozilo prisutno). Drugi tip osjetila magnetskog polja otkriva promjene u Zemljinom magnetskom polju kada vozilo u pokretu prođe preko

zone otkrivanja. Ova su magnetska osjetila induksijski magnetometri. Većina ih ne može otkriti zaustavljena vozila ili njihovo prisustvo jer im je potrebno kretanje kako bi proizveli signal na izlazu.



Slika 8. Magnetska osjetila (© nwavetec i libelium)

3.1.3. Radarska osjetila

Radarska osjetila spadaju u posebne vrste radara. Tipovi prometnih podataka koje prima mikrovalno radarsko osjetilo ovise o valnoj dužini koja se koristi za prijenos mikrovalne energije. Za određivanje brzine vozila koriste se radari s neprekinutim valom, odnosno radari s neprekinutom emisijom odašiljača (*Continuous Wave, CW*). Brzina vozila proporcionalna je promjeni frekvencije između primljenog i odašlanog signala te se stoga određuje mjerenjem te promjene. Dopplerov pomak frekvencije nastaje prolaskom vozila kroz zonu otkrivanja. Emisija i prijam signala teku neprekidno pa je razdvajanje tih signala i osnovni problem njihove konstrukcije [116]. Doppler radar s neprekinutim valom može otkrivati samo vozila u pokretu, a ne i njihovo prisustvo.

Kako bi se mjerilo i prisustvo vozila koristi se frekvencijski modulirani CW radar. Prisustvo vozila se određuje na osnovi promjene udaljenosti do cilja koja se događa kada vozilo dođe u vidno polje radara. Udaljenost se mjeri u razdobljima kada se odašlana frekvencija smanjuje ili povećava tijekom vremena. Ona je proporcionalna razlici frekvencija Δf koja nastaje u odašiljaču između vremena odašiljanja t_{f1} i vremena prijama t_{f2} . Mjerenje brzine vozila postiže se tehnikom dijeljenja vidnog polja. Prilikom prolaska vozila mjeri se vremenska razlika ulaska vozila u svako pojedino polje uz poznatu udaljenost među njima.

Većina komercijalno dostupnih mikrovalnih radarskih osjetila koja se koriste u cestovnom prometu odašilje elektromagnetsku energiju u X frekvencijskom pojasu na frekvenciji od 10,525 GHz. Za višu rezoluciju podataka mogu se koristiti i više frekvencije, ali će pokrivenost biti nešto manja.

3.1.4. Infracrvena osjetila

Infracrvena osjetila mogu raditi u aktivnom ili pasivnom načinu rada. U aktivnom načinu rada, laserske diode koje rade u spektru blizu infracrvenog osvjetljavaju zone otkrivanja. Dio odaslane energije reflektira se kad vozilo putuje kroz zonu. Reflektirana energija dolazi do infracrvenog osjetnika koji je pretvara u električni signal, te se isti analizira u stvarnom vremenu. Prisustvo stacionarnog vozila ili vozila u pokretu određuje se mjerenjem vremena koje je potrebno da se odaslani infracrveni impuls vrati do osjetila nakon što se reflektirao. Vrijeme obilaska je kraće kada je vozilo prisutno u zoni jer je udaljenost od osjetila do vozila manja nego udaljenost od osjetila do prometnice. Brzina vozila mjeri se uporabom dviju fiksnih zraka od kojih je jedna usmjerena malo unaprijed. Brzina vozila izračunava se iz vremenske razlike koja je nastala prolaskom prednjeg dijela vozila kroz svaku pojedinu zraku, uz poznatu udaljenost između zraka. Klasifikacija vozila se može dobiti mjerenjem dvodimenzionalnog visinskog profila vozila. Vozilo se klasificira upotrebom algoritma koji uspoređuje mjerenjem određeni profil vozila sa profilima različitih klasa vozila koji se nalaze spremljeni u bazi podataka.

Pasivna osjetila ne odašilju energiju već otkrivaju energiju koja se odašilje ili reflektira od vozila, površine prometnice i drugih objekata u vidnom polju i iz atmosfere. Izvor energije koju emitira vozilo ili površina prometnice je radijacija sivog tijela proizvedena površinskom temperaturom emisijskog objekta različitom od nule. Kada vozilo uđe u vidno polje osjetila generira se signal koji je proporcionalan umnošku razlike emisije i razlike temperature pod pretpostavkom da su površinske temperature vozila i prometnice jednake. Promjene u emitiranoj energiji koriste se za otkrivanje vozila.

3.1.5. Ultrazvučna osjetila

Ultrazvučna osjetila odašilju tlačne valove zvučne energije na frekvencijama između 25 i 50 kHz koji su iznad granice ljudske čujnosti. Većina ultrazvučnih senzora radi s impulsnim valnim oblicima, te mogu pružati informacije o broju vozila, prisutnosti i zauzetosti. Impulsni valni oblik koristi se za mjerenje udaljenosti do površine prometnice ili vozila otkrivanjem dijela reflektirane energije koja se vraća u osjetilo. Kada se izmjerena udaljenost razlikuje od one izmjerene do površine prometnice, osjetilo ju tumači kao prisutnost vozila. Ultrazvučna energija pretvara se u električnu koja se analizira u pripadnom elektroničkom sklopovlju za obradu signala. Brzina vozila se može mjeriti snimanjem vremena prolaska vozila kroz dvije kalibrirane međusobno blisko postavljene zrake. Ova tehnika je slična tehnici koju koriste laserski radari. Za mjerenje brzine ultrazvučna osjetila mogu koristiti Dopplerov princip i konstantnu frekvenciju, ali je njihova cijena znatno viša od impulsnih modela. Dopplerov je model

prvenstveno napravljen za uporabu u sklopu infrastrukture za upravljanje prometom u Japanu.



Slika 9. Ultrazvučno osjetilo (© parksol)

3.1.6. Akustična osjetila

Akustična osjetila mjere brzinu i protočnost vozila te zauzetost prometnice otkrivajući zvučnu energiju koja je u obliku čujnih zvukova. Zvukove proizvode razni izvori zvukova unutar vozila, ali i interakcija guma s površinom prometnice. Prilikom prolaska vozila kroz zonu otkrivanja, algoritam za obradu signala prepoznaje povećanje energije zvuka i stvara signal koji označava prisutnost vozila. Nakon što vozilo napusti zonu otkrivanja, razina energije zvuka pada ispod praga otkrivanja i nestaje signal koji označava prisutnost vozila.

Osjetila su postavljena u obliku dvodimenzionalnog polja mikrofona koji primaju zvuk proizveden približavanjem vozila. Jedan od modela akustičnih osjetila upotrebljava vremensko kašnjenje između donjih i gornjih mikrofona kako bi otkrio vozilo u određenoj prometnoj traci. Kada je vozilo u zoni otkrivanja zvuk dolazi do svih mikrofona gotovo istovremeno, a kad se nalazi izvan navedene zone gornji mikrofoni primaju zvuk sa zakašnjenjem zbog određenog međusobnog razmaka u odnosu na donje mikrofone. Postavljaju se pod kutom od 10 do 30 stupnjeva, a domet im je od 6 do 10,5 metara. Zvuk nastao izvan zone otkrivanja se prigušuje. Ovaj model osjetila nije prikladan za spori promet vozila s čestim zaustavljanjem i kretanjem.

Drugi tip akustičnog osjetila sadrži gusto popunjeno polje mikrofona i prostorno prilagođenu obradu signala kako bi se omogućilo stvaranje više zona otkrivanja. Osjetilo može biti postavljeno iznad centra prometnice i nadzirati od 6 do 7 prometnih traka istovremeno. Zona otkrivanja u smjeru prometnog toka je veličine zone koju pokriva ILD.

3.1.7. Videoprocessori

Videoprocessori (*Video image processors, VIP*) otkrivaju prisustvo vozila analizom videoslika i otkrivanjem promjena u uzastopnim okvirima. Sustav se obično sastoji od jedne ili više kamera, mikroprocesora za digitalizaciju i obradu slika i odgovarajućeg programa za interpretaciju slika i pretvaranje dobivenih rezultata u podatke o prometnom toku. Algoritmi za obradu slike analiziraju nijanse sive boje u skupini piksela slikovnih okvira videosnimke. Filtriranjem nepoželjnih nijansi sivih tonova koji nastaju uslijed vremenskih uvjeta, raznih sjena na prometnicama i uslijed izmjena dana i noći, može se ukloniti pozadina i izdvojiti objekt od interesa (automobil, kamion, motor, bicikl i sl.). Analizom uzastopnih slikovnih okvira VIP može izračunati informacije o prometnom toku.

VIP sustavi se mogu postaviti tako da prate dolazni i odlazni tok vozila. Problem dolaznog toka vozila je što duga vozila poput kamiona s prikolicom mogu smanjiti preglednost prometnog traka, a upotreba prednjih svjetala vozila po noći zaslijepljuje kameru. Također, kod zavojitih se prometnica vozilo u zavoju može greškom pridružiti krivom prometnom traku. Vozila u odlaznom toku primjećuju se odmah u neposrednoj blizini kamere i jednostavnije se prepoznaju po noći jer stražnja svjetla vozila ne zaslijepljuju kameru već olakšavaju prepoznavanje. Kamere su postavljene najčešće iznad prometnice i imaju puno manji utjecaj na ponašanje vozača.

Tri su različite kategorije VIP sustava. U prvoj kategoriji sustava korisnik može odrediti ograničeni broj zona otkrivanja u vidnom polju videokamere. Kada vozilo prođe jednom od prethodno određenih zona bilježi se promjena piksela na slici koju je izazvalo prisustvo vozila na prometnici. Druga kategorija sustava omogućava otkrivanje vozila na većem segmentu prometnice. Ovakvi sustavi pružaju dodatne informacije o prometnom toku poput promjene prometnog traka. Treća kategorija sustava može prepoznati i pratiti određeno vozilo ili grupu vozila kada prođu kroz vidno polje kamere. Vozila se prepoznaju pronalaženjem karakterističnih područja koje sačinjavaju susjedni pikseli i zatim se ta područja traže u uzastopnim slikovnim okvirima kako bi se proizveli podaci za praćenje odabranog vozila ili grupe vozila. Buduća primjena praćenja uz pridružene podatke omogućit će prepoznavanje i praćenje vozila kako ista prolaze od vidnog polja jedne do vidnog polja druge kamere, te će predstavljati osnovu za izračunavanje vremena putovanja i pružati informacije o ishodištu i odredištu. Također, isti bi sustav mogao pronaći svoju primjenu u pronalaženju vozila koje kruži u potrazi za raspoloživim parkirališnim mjestom.

3.2. Napredne tehnologije za lociranje vozila i navigaciju

Automatska lokacija vozila (*Automatic Vehicle Location, AVL*) predstavlja cijeli niz tehnologija koje uključuju tehnologije pozicioniranja, mapiranja i komunikacije. AVL tehnologije se rijetko koriste kao samostalne aplikacije već su sastavni dio mnogih ITS servisa poput rutnih vodiča, tranzitnih putničkih informacija, upravljanja flotom komercijalnih vozila, računalno pomognutog otpremništva, otkrivanja zagušenja i povratka ukradenih vozila. Osnovne komponente AVL i navigacijskih tehnologija su:

- lokacijske tehnologije i pozicijski sustavi
- mape
- geografski informacijski sustavi (GIS) i map-matching
- rutni vodiči i tehnologije pronalaženja puta
- tehnologije prikazivanja i distribucije informacija.

3.2.1. Pozicijski sustavi

Četiri se tipa pozicijskih tehnika koriste za ITS: navigacija pomoću proračunavanja puta (*dead reckoning*), satelitski pozicijski sustavi, zemaljska radiofrekvencija i *map-matching*.

Satelitski pozicijski sustavi koriste se u svim modovima transporta. Primjer sustava za globalno pozicioniranje (*Global positioning system, GPS*) je radiopozicioniranje koje se temelji na satelitima Ministarstva obrane Sjedinjenih Američkih Država. Sateliti primaju i spremaju podatke prenesene s kontrolnih postaja, zadržavaju precizno vrijeme svojim atomskim satovima i prenose informacije korisnicima. Zemaljske kontrolne postaje odgovorne su za praćenje satelita, izračunavanje orbita, telemetriju i niz drugih aktivnosti potrebnih za kontrolu satelita. Pregled globalnih navigacijskih satelitskih sustava (GNSS) prikazan je u tablici 5.

U navigaciji pomoću proračunavanja puta trenutna se pozicija izračunava na osnovi posljednje poznate pozicije vozila te njegovog smjera i brzine. Brzina, udaljenost i smjer mjere se različitim osjetilima uključujući odometre, visinomjere, kompase, brzinomjere i inercijska osjetila poput akcelerometra i žiroskopa. Dobiveni se podaci koriste za određivanje pozicije. Najveći nedostatak ovih uređaja je velika akumulacija pogreške jer se i najmanja pogreška tijekom vremena značajno uvećava. Obično se integriraju sa globalnim pozicijskim sustavima kako bi se prevladali nedostaci obaju sustava.

Tablica 5. GNSS klasifikacija

GNSS 1	Sustav prve generacije i kombinacija postojećih satelitskih navigacijskih sustava (GPS-a/NAVSTAR i GLONASS-a) sa satelitski baziranim augmentacijskim sustavima (<i>Satellite Based Augmentation Systems</i> , SBAS) ili zemaljski baziranim augmentacijskim sustavima (<i>Ground Based Augmentation Systems</i> , GBAS). SBAS se u Sjedinjenim Američkim Državama može pronaći pod nazivom Širokopodručni augmentacijski sustav (<i>Wide Area Augmentation System</i> , WAAS), u Europi se naziva Europska geostacionarna navigacijska prekrivajuća služba (<i>European Geostationary Navigation Overlay Service</i> , EGNOS), u Indiji GPS i GEO augmentacijska navigacija (<i>GPS and GEO Augmented Navigation</i> , GAGAN), a u Japanu Multifunkcionalni satelitski augmentacijski sustav (<i>Multi-Functional Satellite Augmentation System</i> , MSAS). Zemaljsku baziranu augmentaciju pružaju sustavi poput Lokalnih augmentacijskih sustava (<i>Local Area Augmentation System</i> , LAAS).
GNSS 2	Sustavi druge generacije koji neovisno pružaju podršku potpunim civilnim satelitskim navigacijskim sustavima, primjerice europskom pozicijskom sustavu Galileo. Ovi sustavi pružit će praćenje s točnošću i integritetom potrebnim za civilnu navigaciju. Koriste frekvencije L1 i L2 za civilnu uporabu i L5 za integritet sustava. Razvoj postojećeg GPS osigurao bi frekvencije L2 i L5 za civilnu uporabu, te tako postao sustav GNSS-2.
Osnovni satelitski navigacijski sustavi	GPS, Galileo i GLONASS.
Globalni satelitski bazirani augmentacijski sustavi	Omnistar i StarFire.
Regionalni satelitski bazirani augmentacijski sustavi	WAAS (SAD), EGNOS (EU), MSAS (Japan) i GAGAN (Indija).
Regionalni satelitski navigacijski sustavi	QZSS (Japan), IRNSS (Indija) i Beidou (Kina).
Kontinentalni GBAS	FAA GBAS, Australski GRAS.
Regionalni GBAS	Referentne postaje (<i>Continuously Operating Reference Stations</i> , CORS)
Lokalni GBAS	Referentne postaje u sklopu zračnih luka.

Izvor: Prilagodio autor na osnovi "A Beginner's Guide to GNSS in Europe", EVP Europe, International Federation of Air Traffic Controller's Associations, 1999.

Poseban pristup određivanju pozicije je uporabom mobilnih uređaja (Slika 10.). Osnovna je prednost ovoga pristupa mogućnost korištenja postojeće infrastrukture što značajno umanjuje troškove uspostavljanja jedne ovakve usluge. Mobilna telefonija već ima dodijeljeni frekvencijski opseg i veliku bazu korisnika koja je potrebna za podršku ovakvoj ideji.



Slika 10. Navigacijski sustav tvrtke *Navigon* na priključnim mobilnim uređajima

U svrhu pozicioniranja i navigacije koriste se različite mape obično rasterskog ili vektorskog tipa. Rasterske su mape u osnovi slike koje su prikladne za pokazivanje detalja poput visinskih razlika upotrebom topografskih oznaka. Vektorske su mape crteži sastavljeni od točaka, linija i poligona spremljenih u bazu podataka u obliku x i y koordinata. Vektorske mape prikazuju znatno manje grafičkih detalja od rasterskih mapa.

Rasterske mape imaju niz nedostataka koji ih, bez obzira na njihove prednosti, čine gotovo neupotrebljivima u većini AVL aplikacija. One zahtijevaju daleko više memorijskog prostora od vektorskih mapa, potrebno im je znatno više vremena za iscrtavanje na zaslonu uređaja i fiksne su u odnosu na orijentaciju jer se njihovim zakretanjem okreće i tekst koji sadrže pa se isti prikazuje naopako. Također, bez obzira na uvećanje ili smanjenje mape uvijek se prikazuje ista količina detalja, a dijelovi s tekstom mogu postati potpuno nečitki. Za razliku od rasterskih mapa, vektorske mape su puno prikladnije za navigaciju jer se mogu povećavati i smanjivati bez gubitka detalja, tekst na mapi se prilagođava zakretanju i razini uvećanja tako te je uvijek čitljiv za korisnike i ovisno o stupnju uvećanja mogu prikazivati više ili manje informacija.

Geografski informacijski sustavi koriste se za upravljanje prostornim i geografskim podacima. Uz cijeli niz mogućnosti koje pružaju takvi sustavi, oni ostvaruju veze između specifičnih informacija o poziciji poput koordinata i geografskih informacija kao što su nazivi

mjesta, ulica i adrese. Često su koordinate pridružene samo glavnim raskrižjima u određenim područjima, a kućni se brojevi interpoliraju između onih poznatih što rezultira pogreškama u sustavu za pozicioniranje. Za određivanje pozicije vozila u odnosu na mapu koriste se *map-matching* tehnike. One se koriste za izbjegavanje učinaka pogrešaka koje nastaju zbog nesavršenosti globalnih pozicijskih sustava. Na primjer ako GPS daje koordinate koje ne odgovaraju precizno cesti na digitalnoj mapi *map-matching* algoritam će pronaći najbližu cestu i locirati vozilo na njoj. Kako se vozilo kreće podaci dobiveni putem različitih osjetila uspoređuju se s cestovnom mrežom digitalne mape. Za pozicioniranje vozila koriste se koordinate poznatih objekata i elemenata poput spomenutih raskrižja. Ova tehnika zahtijeva precizne mape koje predstavljaju stvaran svijet, jer ako vozilo putuje prometnicom koja ne postoji na mapi tada *map-matching* algoritam smatra taj put nevažecim.

Jednom kada je pozicija vozila poznata AVL sustav može iscrtati put od trenutne lokacije do odredišta. Navigacijski sustavi u vozilu obično tu informaciju daju direktno vozaču. Inteligentni sustavi mogu analizirati više putova kako bi predložili onaj koji u najvećoj mjeri smanjuje utrošak goriva i trošenje vozila i guma.

3.2.2. Tehnologije za prikaz i pružanje informacija

Nove su tehnologije omogućile putnicima pristup informacijama na različitim lokacijama. Informativni kiosci, radijski i televizijski uređaji, znakovi s dinamičkim porukama (*Dynamic message sign*, DMS) i uređaji fiksne telefonije godinama se koriste u svrhu pružanja informacija. Pristup informacijama koje su pružane tim tehnologijama bio je prostorno i vremenski ograničen te se nije mogao usmjeravati na unaprijed određene skupine korisnika. Posljednjih je godina uporaba mobilnih uređaja i interneta osigurala jednu sasvim novu alternativu. Mobilni su uređaji omogućili pristup informacijama bilo kada i na bilo kojem mjestu, a u prilog tome ide i činjenica da je pristup internetu iz kućanstava ili s radnih mjesta u stalnom porastu. Uz moderna informatička rješenja i cijeli niz različitih usluga, pružanje informacija je sve učinkovitije. U nastavku će biti prikazani znakovi s dinamičkim porukama i radijske tehnologije.

3.2.2.1. Znakovi s dinamičkim sadržajem

Znakovi s dinamičkim sadržajem mogu sadržavati poruke ili ilustracije, odnosno kombinaciju poruka i ilustracija koje se dinamički izmjenjuju na osnovi pristiglih informacija. Osnovna svrha znakova s dinamičkim sadržajem je pružanje informacija putnicima prije i u vrijeme putovanja. U praksi se učestalije pojavljuju znakovi s promjenjivim porukama čiji je sadržaj i dužina određen uvjetima na prometnici i dozvoljenom brzinom vožnje. Ovi znakovi imaju dinamički, odnosno promjenjivi displej koji

kod starijih inačica može biti gotovo u cijelosti mehanički, a danas se pojavljuje u obliku najmodernijih znakova s promjenjivim porukama (*Variable message sign*, VMS) na autocestama i drugim prometnicama. Iako postoje različite izvedbe ovih uređaja u ovome će se radu prikazati samo VMS kao njihov najznačajniji predstavnik. Na tržištu su dostupni u različitim izvedbama i koriste brojne tehnologije, ali u principu se sve inačice koriste upravljivim pikselima pomoću kojih se oblikuje displej. Znakovi mogu biti fiksno vezani za prometnu infrastrukturu ili prenosivi (najčešće na kotačima ili kao dio vozila službe održavanja prometnica). Poruke mogu biti različitog sadržaja, ali se općenito dijele na tri skupine: poruke ranog upozorenja, savjeti vozačima i poruke o alternativnim rutama [117]. Njihov sadržaj mora biti jasan, precizan, pouzdan, svrsishodan i stvarnovremenski jer će u suprotnom vozači izgubiti povjerenje u ovaj tip prometne signalizacije [118]. Tehnologije koje se najčešće primjenjuju u okviru inteligentnih transportnih sustava su reflektirajuće ploče, matrice žarulja, svijetleće diode (*light emitting diodes*, LED), svjetlovodni okidači (*Fiber optic shutter*, FOS), hibridni svjetlovodi i hibridne svijetleće diode.

a) Reflektirajuće ploče

Ovom se tehnologijom poruka prikazuje preklapanjem ploča ili kocki koje su s jedne strane crne s niskim sjajem, a s druge strane presvučene fluorescentnim ili retroreflektirajućim materijalom. Ploče imaju širok kut vidljivosti, ali trebaju osvjjetljenje da bi se vidjele noću.

b) Matrice žarulja

VMS s matricom žarulja prikazuje poruke korištenjem piksela koje oblikuju žarulje. Svaka žarulja može predstavljati jedan piksel ili se u istu svrhu može koristiti skupina žarulja. Složenije izvedbe koriste leće u boji koje se pale različitom učestalošću i na taj način stvaraju animacije u boji. Osnovni su im nedostaci visoki zahtjevi za održavanjem i zamjenom žarulja te znatno viša potrošnja električne energije.

c) Svijetleće diode

LED VMS koriste svijetleće diode za prikazivanje piksela koji će činiti poruku. Za svaki se piksel koristi jedna ili više svijetleća dioda spojenih tako da se u slučaju neispravnosti zadrži funkcionalnost displeja. Najčešće se koriste diode sa žutim svjetlom. Nedostatak im se očituje u potrebi za ventilacijskim sustavom koji će hladiti unutrašnjost VMS displeja. LED VMS imaju visoku vidljivost, ali ipak nešto manju od svjetlovodnog VMS-a.



Slika 11. VMS u Rijeci

d) FOS

Kod ove se tehnologije koriste lampe visokog intenziteta (obično kvarc-halogene) kojima se osvijetljavaju završetci snopa svjetlovodnih niti. Snopovi se grupiraju i umeću u okidač. Okidači su organizirani u piksele kako bi se oblikovao VMS displej. Zatvaranje ili otvaranje okidača postiže se elektromagnetskim elementom ili zatvaračem. Imaju veliku vidljivost čak i u nepovoljnim uvjetima okoline i dostupni su u širokom spektru boja.

e) Hibridni svjetlovodi i svijetleće diode

Ovi znakovi kombiniraju karakteristike reflektirajućih ploča s prednostima svjetlovoda ili svijetlećih dioda. Kada je sunčeva svjetlost usmjerena prema znaku, reflektirajuće ploče pružaju širok kut vidljivosti i dobar kontrast, a u lošim uvjetima okoline ili po noći visoku vidljivost osiguravaju LED ili svjetlovodne tehnologije. Uslijed činjenice da je potrošnja energije reflektirajućih ploča gotovo jednaka nuli i da se LED tehnologija koristi samo po potrebi, ušteda energije je značajna.

3.2.2.2. Radiosustavi

Prometne se informacije mogu pružati korisnicima i putem radioveze. To se može činiti pomoću uobičajenih servisnih informacija o stanju u prometu koje su sastavni dio radijskog programa komercijalnih radiopostaja ili putem tzv. HAR sustava (*Highway Advisory Radio*) i RDS-a (*Radio data System*).

a) HAR

Tradicionalno se informacije o stanju u prometu i na prometnicama prosljeđuju vozačima upotrebom odašiljača ograničenog opsega na AM i FM radioprijamnike u vozilu. HAR se koristi za pružanje obavijesti i upozorenja vozačima o nezgodama ili zagušenjima, nepovoljnim vremenskim uvjetima (kiša, snijeg, led, magla), održavanju i radovima na prometnicama, a može sadržavati i turističke informacije, informacije o zračnim lukama ili alternativnim rutama.

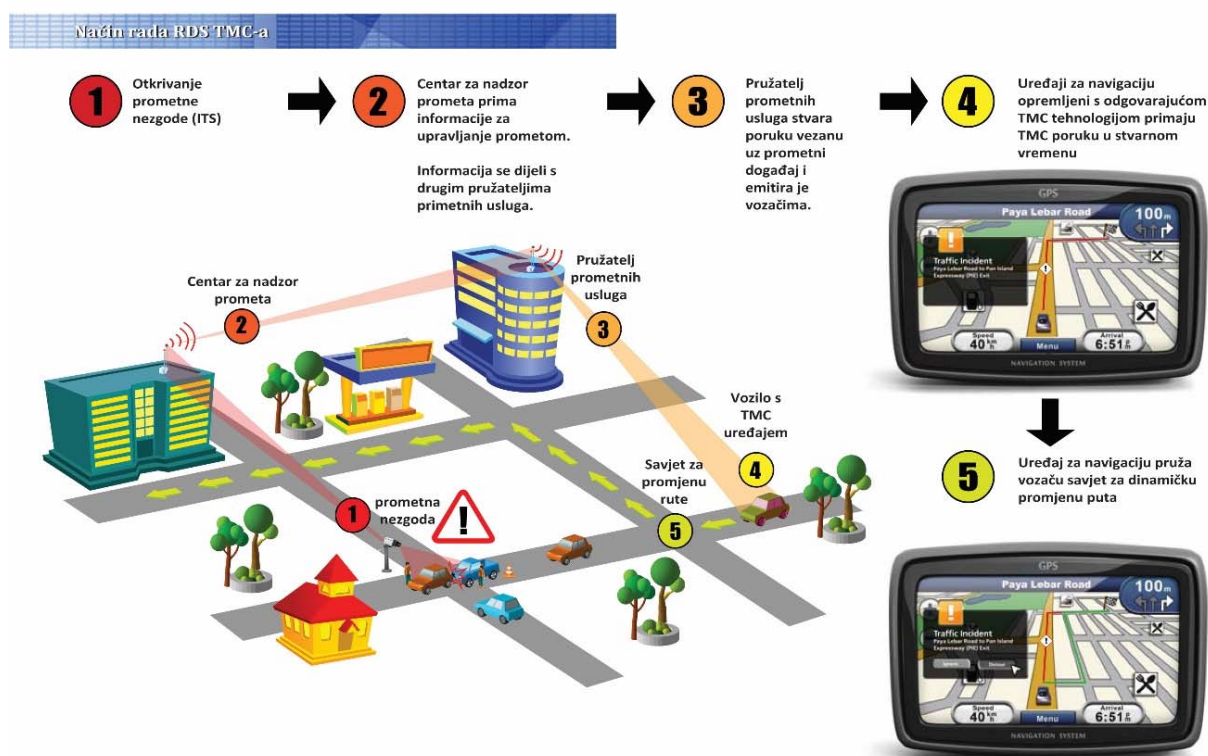
HAR sustavi su učinkovito sredstvo za povremeno informiranje korisnika o stanju na prometnicama i ostalim uvjetima putovanja. U slučaju nastanka događaja od interesa za putnike na određenoj prometnoj dionici, vozače se prije dolaska u područje pokrivenosti HAR signalom putem VMS-a upućuje na prebacivanje trenutne frekvencije radiouređaja na frekvenciju signala s prometnim informacijama. Informacije koje se prenose korisnicima su najčešće unaprijed snimljene iako sustavi mogu prenositi i poruke operatera uživo.

Sustavi se obično sastoje od jednopolne vertikalno polarizirane antene ili antene s ukopanim koaksijalnim kabelom, podsustava uzemljenja, cestovnog odašiljača male snage, komunikacijske veze s kontrolnim centrom, uređaja za snimanje poruka i odgovarajućih prometnih znakova za upućivanje vozača na prisutnost sustava. Odašiljanje poruka se može kontrolirati s udaljene lokacije ili na licu mjesta i najčešće se prenose na frekvencijama od 530 do 1610 kHz. Iako su poruke koje vozači dobivaju na ovaj način puno duže, sadržajnije i cjelovitije od poruka koje se mogu dobiti dinamičkim prometnim znakovima te mogu pružiti neophodne informacije većem broju korisnika, vozači moraju poduzeti direktnu akciju kako bi primili informacije. Osnovni im je nedostatak mala snaga odašiljanja (ograničena

propisima) što se često očituje u lošoj kvaliteti signala. Područje pokrivenosti ovim signalom je relativno malo i iznosi od 5 do 7 km. HAR sustavi mogu biti i automatski te po potrebi preuzimati kontrolu nad radio emisijom u vozilu i emitirati informativne poruke i savjete vozačima.

b) RDS

Radiopostaje obično koriste samo mali dio dodijeljenog im frekvencijskog opsega za emitiranje radio emisija. RDS koriste jedan dio toga spektra za prijenos informacija u digitalnom obliku. RDS signal ima isti opseg i istu razinu pouzdanosti kao radiopostaja čiju frekvenciju koristi. Digitalna informacija koja se ovim putem prenosi ne ometa emitiranje glasovnog programa. Uređaj opremljen RDS prijemnikom prima signal i dekodira ga ili prevodi u tekstualnu ili glasovnu poruku koja se zatim prosljeđuje korisniku putem zvučnika ili displeja samog uređaja.



Slika 12. Princip rada RDS-TMC

U svrhu pružanja informacija vozačima motornih vozila koriste se navedene mogućnosti digitalnog prijenosa podataka te se prometne informacije prenose putem RDS kanala s prometnim porukama (*RDS Traffic Message Channel*, RDS TMC). RDS-TMC predstavlja normiranu tehnologiju i protokol (ISO14819) oblikovanu na način pružanja vozačima motornih vozila stvarnovremenske putne i prometne informacije. TMC informacije se

emitiraju putem FM RDS komunikacijskog protokola, no moguće ih je prenositi i GPRS i DAB protokolima⁵. Prometne se informacije mogu prikazivati u obliku tekstualnih poruka na radiodisplejima ili u nekom grafičkom obliku na prijenosnim uređajima za navigaciju poput navigacijskog sustava u vozilu. Niska propusnost ovoga protokola čini ga isplativim oblikom distribuiranja prometnih informacija.

Široka primjena RDS TMC tehnologije započela je u Japanu i europskim zemljama, a zbog stanovitih ograničenja znatno kasnije u SAD. Danas se navedeni sustav može pronaći i na azijskom kontinentu te zemljama Bliskog istoka.

3.2.2.3. Ostale metode informiranja putnika

Radio i televizija su jedan od prvih oblika informiranja putnika prije kretanja na putovanje. Izvješća o stanju na cestama i ostale prometne i putne informacije dio su njihovog svakodnevnog programa. Sljedeća generacija uređaja koja je nakon ugradnje RF komunikacijske tehnologije postala sposobna pružati prometne pretputne i putne informacije bili su dlanovnici (*Personal Data Assistants*, PDA), koji pružaju mogućnost korisnicima ostvarivati određenu direktnu interakciju sa sustavima za informiranje kako bi dobili odgovarajuću pomoć pri planiranju putovanja i druge važne informacije. Učinkovitost interneta kao brzog i elastičnog medija potaknula je brz razvoj u svim segmentima društva. Internetski servisi koji pružaju pretputne informacije koriste se svakodnevno, a broj stranica koje sadrže prometne informacije u stalnom je porastu. Većina tih stranica sadrži informacije o prometnom toku u obliku mapa s oznakama u boji, savjete za planiranje puta, slike i videozapise prometnica, obavijesti o radovima na cesti i održavanju, novosti o stanju na cestama i vremenskim uvjetima, poveznice s drugim internetskim stranicama sa sličnom tematikom, itd. Prijenosna računala i sve napredniji mobilni uređaji omogućila su pristup prometnim informacijama ne samo s radnog mjesta i iz kućanstava već i u pokretu, neovisno gdje se putnici u određenom trenutku nalaze.

3.3. Sustavi za navigaciju i upućivanje vozila

Razvoj današnjih dinamičkih sustava za navigaciju i upućivanje vozila započeo je s razvojem sustava za pozicioniranje (poput proračunavanja puta, *map-matching* i satelitskih sustava) te komunikacijskih sustava za prikupljanje i distribuiranje informacija (npr. RDS). Skupine statičkih i dinamičkih prometnih znakova (DMS, VMS) mogli bi prozvati prvim sustavima za navigaciju. Prvi sustavi za navigaciju i upućivanje vozila sadržavali su najbolje od početno navedenih tehnologija, odnosno, koristile su kombinaciju statičkih navigacijskih tehnologija i dinamičkih prometnih informacija. Sva vozila koja su imala ugrađene sustave

⁵ *General Packet Radio Service* i *Digital Audio Broadcast*.

za navigaciju dobivala su podatke iz kontrolnog centra, no ta komunikacija je bila jednosmjerna.

Nedugo zatim uslijedio je očekivani razvoj dvosmjernog ili dinamičkog sustava za navigaciju i upućivanje vozila koji je, osim jednosmjerne komunikacije između prometnog centra i vozila s odgovarajućom opremom, omogućavao komunikaciju i u drugom smjeru te omogućio indirektno dijeljenje informacija o prometnoj situaciji između vozila.

Tijekom 80-ih i početkom 90-ih godina prošlog stoljeća provode se opsežna istraživanja u Europi (DRIVE I – 1989., DRIVE II – 1992., PROMETHEUS – 1986., AUTOGUIDE – 1987., ALISCOUT – 1987.), USA (TRAVTEK – 1993., ADVANCE, PATHFINDER – 1992., ROGUE – 1989., CARIN – 1987.) i Japanu (RACS – 1984., AMTICS – 1989., VICS – 1991.) [54]. Ove inicijative⁶ nažalost nisu nikad u cijelosti zaživjele osim projekta VICS (*Vehicle Information Communication System*) koji se i dalje aktivno koristi u Japanu.

Početkom ovoga stoljeća broj usluga koje nude rutne vodiče enormno raste što se vezuje uz pristupačnost osobnih navigacijskih uređaja (*Personal Navigation Devices*, PND) čija cijena sve više pada. Procjenjuje se da je 2010. godine u Europi 25 % vozila imalo ugrađenu nekakvu vrstu navigacijskog uređaja, dok je taj udio u Sjevernoj Americi iznosio 20 % (TomTom). Usluge rutnih vodiča doživljavaju kontinuiranu promjenu uslijed stalnih inovacija. Pojavljivanjem pametnih mobilnih uređaja veliki dio aplikacija i usluga rutnih vodiča i navigacije postaje široko dostupan i štoviše besplatan, pa navigacija prerasta u standard i gotovo je neizostavni dio opreme vozila. Usporedo s razvojem navigacijskih usluga razvijaju se i mape koje se koriste u tu svrhu. 2D mape zamjenjuju se 3D inačicama koje znatno olakšavaju navigaciju.

Usluge rutnog vodiča i navigacije u javnom i privatnom vlasništvu susreću se sa sličnim problemima pri pružanju čim kvalitetnijih savjeta. Upute koje pružaju vozačima najčešće se zasnivaju na slobodnom prometnom toku, trenutnom vremenu putovanja i raspoloživim povijesnim podacima, no učinak zagušenja koji se može iskusiti tijekom putovanja rijetko se ispravno uzima u obzir. Rastući problemi sa zagušenjima u gradskim središtima sve više naglašavaju potrebu za dinamičkim upravljanjem prometom i boljim iskorištenjem

⁶ Navedene inicijative potakle su i proizvodnju prvih sustava za navigaciju i informiranje u vozilu. U Europi su to bili Boschov/Blaupunktov sustav – German Autofahrer Leit und Informationssystem (ALI), Siemensov AUTO-SCOUT sustav, Boschov TravelPilot koji se zasnivao na ETAK sustavu i Phillipsov CAR Information and Navigation (CARIN) sustav, zatim u USA ETAK Navigator i NavMate tvrtke Zexel Corporation, te u Japanu Toyotin Electro-multivision, Nissanov Drive Guide, Hondin Electro-gyrolocator i MAPIX III tvrtke Nippondenso.



Slika 13. Navigacijski sustav u Audi vozilima

prometne infrastrukture, čime se u prvi plan stavlja i učinkovita uporaba sustava za navigaciju i upućivanje vozila. Kooperativni pristup predstavlja jednu od metoda koja bi trebala omogućiti jednostavnije postizanje navedenog cilja. Na slici 13. prikazan je novi sustav za navigaciju Audi vozila koji je smješten na komandnoj ploči ispod volana i prema raspoloživim podacima predstavlja prvi takav slučaj u svijetu.

4. KOOPERATIVNI INTELIGENTNI TRANSPORTNI SUSTAVI U CESTOVNOM PROMETU

Osnovna zadaća kooperativnih inteligentnih transportnih sustava (C-ITS) je poboljšanje cestovnog prometa. To poboljšanje bi se prije svega trebalo odnositi na smanjenje zagušenja prometnica, skraćivanje vremena putovanja, povećanje cestovne sigurnosti, smanjenje utjecaja vozila na okolinu te bogatija iskustva vozača.

Kooperativni sustavi su skupina tehnologija i aplikacija koje omogućavaju učinkovitu razmjenu podataka putem bežičnih tehnologija između elemenata i sudionika transportnih sustava, odnosno između dvaju vozila (*vehicle-to-vehicle*, V2V) ili između vozila i infrastrukture (*vehicle-to-infrastructure*, V2I)⁷. Ipak, C-ITS treba promatrati kao puno širi pojam koji nije ograničen samo na V2V ili V2I komunikaciju, već uključuje i primjenu na osjetljive sudionike u cestovnom prometu poput pješaka, biciklista i motorista.

Općenito je prihvaćena činjenica da je C-ITS evolucijski proces koji će započeti s puno manje složenim primjenama u prometu zadovoljavajući različite sudionike. Vrlo je važno imati na umu širinu ove vizije u kojoj pojedini događaji u prometu mogu izazvati više procesa koji će prenositi informacije, odnosno podatke u različite svrhe i tako dovesti do kooperativnih sustava različitih namjena koji opet mogu koristiti različite komunikacijske tehnologije. Cilj je zadržati holistički pristup unutar inteligentnih transportnih sustava i ne odbacivati niti jednu tehnologiju.

Osnovna je zamisao kooperativnih sustava u vozilu nastala prije desetak godina. Mobilna automobilska mreža koja je uglavnom opisivana u akademskim i istraživačkim krugovima pod nazivom VANET (*Vehicular ad hoc*⁸ *network*) sastavni je dio puno šire ideje mobilne bežične mreže MANET (*Mobile ad hoc network*) odnosno WANET (*Wireless ad hoc network*). Dok se MANET može definirati kao mreža mobilnih uređaja bez posebne infrastrukture koji imaju karakteristiku samougađanja i spojeni su bežično, VANET u tu svrhu koristi vozila kao mobilne čvorove. VANET pretvara svako vozilo koje je dio mreže u svojevrsni usmjerivač (*router*) i time omogućuje vozilima koja su na udaljenosti između 100 i 300 metara stvaranje

⁷ U literaturi se gotovo jednoznačno koriste i kratice C2C i C2I, odnosno oblik V2X ili C2X koji podrazumijeva oba oblika komunikacije i onaj prema vozilu i onaj prema infrastrukturi.

⁸ Ad hoc je latinski izraz koji znači "zbog ovog" ili "zbog ove svrhe". U općenitom smislu ad hoc označava neko rješenje za neki specifični problem ili zadaću koji se ne generalizira, te koji se ne smije primjenjivati u druge svrhe.

širokopojasne mreže. Ovako nastalu mrežu ne čine samo vozila već i uređaji u infrastrukturi s odgovarajućom komunikacijskom opremom (*Road Side Units*, RSU). Sve navedene karakteristike, uz zamjetan pad cijena elektroničkih komponenata i kontinuiranu volju proizvođača za povećanjem cestovne sigurnosti, dovele su do trenutka kada se vozilo može promatrati kao „računalo na kotačima“.

VANET u usporedbi s MANET-om ima nekoliko jedinstvenih karakteristika [119]:

- potencijalno velik broj čvorova – očekivanja su da će se sve više i više vozila opreмати odgovarajućom komunikacijskom opremom. Uzimajući u obzir i sve RSU, VANET će trebati biti skalabilan s vrlo velikim brojem čvorova;
- visoka mobilnost i učestale promjene topologije – komunikacijski se čvorovi periodično vrlo brzo kreću što ostavlja relativno malo vremena za razmjenu podatkovnih paketa;
- visoki zahtjevi aplikacija za isporukom podataka – izbjegavanje cestovnih incidenata i prometna sigurnost jedne su od najznačajnijih VANET primjena. One imaju visoke zahtjeve u pogledu pouzdanosti i stvarnovremenskim podacima. Kašnjenje u mreži u trajanju od samo jedne sekunde informaciju može učiniti besmislenom i neupotrebljivom;
- sigurnosne informacije nisu povjerljive – informacije sadržane u porukama interesantne su svim cestovnim korisnicima i stoga ne mogu biti povjerljive;
- privatnost – komunikacijske mogućnosti u vozilu mogu otkrivati informacije o vozačima i korisnicima poput njihovih identiteta, brzina vozila, pozicije i karakterističnih obrazaca kretanja. Neovisno o potrebama za potvrdom autentičnosti i neospornosti sigurnosnih poruka, privatnost korisnika i vozača mora biti poštivana pogotovo u pogledu trenutne pozicije i anonimnosti.

Iako su MANET i VANET vrlo slični prema mnogim karakteristikama neki parametri se ipak bitno razlikuju što je prikazano u tablici 6.

Uvidjevši korist od ovakvog pristupa vodeći svjetski proizvođači vozila (Audi, BMW, Daimler, Ford, Honda, Hyundai, Jaguar Land Rover, MAN, Opel, Peugeot Citroen, Renault, Volkswagen, Volvo i Yamaha) osnivaju komunikacijski konzorcij pod nazivom CAR 2 CAR Communication Consortium uz podršku proizvođača opreme i istraživačke zajednice. Osnovna je zadaća ove neprofitne organizacije daljnje unaprjeđenje sigurnosti i učinkovitosti cestovnog prometa uz pomoć kooperativnih inteligentnih transportnih sustava s V2V i V2I komunikacijom.

Tablica 6. Usporedba MANET i VANET parametara [120]

Parametar	MANET	VANET
cijena proizvodnje	jeftina	skupa
promjena u mrežnoj topologiji	spora	učestala i jako brza
mobilitnost	niska	visoka
gustoća čvorova	rijetka	gusta i često promjenjiva
pojasna širina	stotinu kps	tisuću kps
opseg	do 100 m	do 500 m
životni vijek čvora	ovisi o izvoru napajanja	ovisi o životnom vijeku vozila
multihop usmjeravanje	raspoloživo	jedva raspoloživo
pouzdanost	srednja	visoka
uzorak kretanja čvorova	slučajan	uobičajen
način adresiranja	temeljen na atributima	temeljen na poziciji
prikupljanje podataka o poziciji	uporabom ultrazvuka	uporabom GPS-a, radara

Uz već spomenute kratice V2X i C2X u praksi se često upotrebljava i izraz povezana vozila (*connected vehicle, connected car*). Izraz se odnosi na aplikacije, servise i tehnologije koje povezuju vozilo s okolinom u kojoj se nalazi. Iako se općenito povezanim vozilom smatra vozilo koje raspolaže lokalnom bežičnom mrežom i pristupom internetu, u njemu su zapravo prisutni uređaji koji imaju sposobnost spajanja s drugim uređajima u vozilu ili s uređajima, mrežama, aplikacijama i servisima izvan vozila. U pravilu, vozila koja sadrže interaktivne napredne sustave pomoći vozaču (*advanced driver-assistance systems, ADAS*) i kooperativne inteligentne transportne sustave smatraju se povezanim. ADAS tehnologija može se zasnivati na sustavima kamera, senzorskim tehnologijama, podatkovnim mrežama u vozilu te V2V i V2I sustavima. V2V komunikacijska tehnologija može ublažiti posljedice sudara i smanjiti prometna zagušenja razmjenom osnovnih sigurnosnih informacija poput lokacije, brzine i smjera između vozila koja se nalaze u dometu te dopuniti postojeće sigurnosne sustave novim mogućnostima kao što su izbjegavanje frontalnih sudara ili otkrivanje mrtvog kuta.

4.1. C-ITS arhitektura

Arhitektura se kooperativnih sustava obično sastoji od triju različitih domena: domene u vozilu, ad hoc domene i infrastrukturne domene.

Domena u vozilu sastoji se od mreže koja sadrži jedinicu u vozilu (*On-board unit*, OBU) i jednu ili više aplikacijskih jedinica (*application unit*, AU). AU je obično uređaj koji pokreće jednu ili više aplikacija i koristi OBU u komunikacijske svrhe. On može biti integrirani dio vozila i stalno spojen na OBU ili prijenosni uređaj poput prijenosnog računala, dlanovnika ili igraće konzole koji se mogu dinamički spajati i odspajati od OBU. AU i OBU mogu biti spojeni žično ili bežično uporabom bluetooth tehnologije, bežične univerzalne serijske sabirnice (*Wireless Universal Serial Bus*, WUSB)⁹ i sl. Ove dvije jedinice odvojene su samo logički što znači da prema potrebi mogu biti fizički smješteni u jedan uređaj.

Ad hoc domena predstavlja zapravo VANET i sastoji se od vozila opremljenih s OBU i stacionarnih jedinica duž prometnice (RSU). OBU je opremljen s najmanje jednim uređajem kratkog dometa za bežičnu komunikaciju čija je osnovna namjena vezana uz cestovnu sigurnost te opcionalno s drugim komunikacijskim uređajima. Više ovakvih jedinica formira MANET koji omogućuje komunikaciju između čvorova na potpuno distribuiran način bez potrebe za centralnom jedinicom za upravljanje. U svrhu komunikacije s određitim uređajima OBU koristi mogućnost direktne komunikacije bežičnom vezom ili namjenske protokole za usmjeravanje koji omogućuju multihop komunikaciju ako ne postoji mogućnost direktnog povezivanja gdje se podaci prosljeđuju od jedinice do jedinice dok ne dođu do odredišta. Osnovna uloga RSU je unaprjeđenje cestovne sigurnosti slanjem, primanjem i prosljeđivanjem podataka u ad hoc domenu s ciljem proširenja pokrivenosti ad hoc mrežom. Ad hoc mreža sastoji se od čvorova koje predstavljaju mobilne OBU i statičke RSU. Komunikacija između čvorova se zbog sigurnosne politike ostvaruje uz upotrebu sigurnosnih vjerodajnica i digitalnih certifikata odgovarajućeg tijela ovlaštenog za certifikaciju. RSU može biti spojen na mrežnu infrastrukturu koja pak može biti spojena s internetom. RSU može dozvoliti pristup infrastrukturi bilo kojem OBU koji se nalazi u dometu čime se omogućuje da svaki AU koji je registriran na OBU komunicira s bilo kojim uređajem spojenim na Internet, ako to već nije omogućeno direktno komunikacijskim mogućnostima u vozilu.

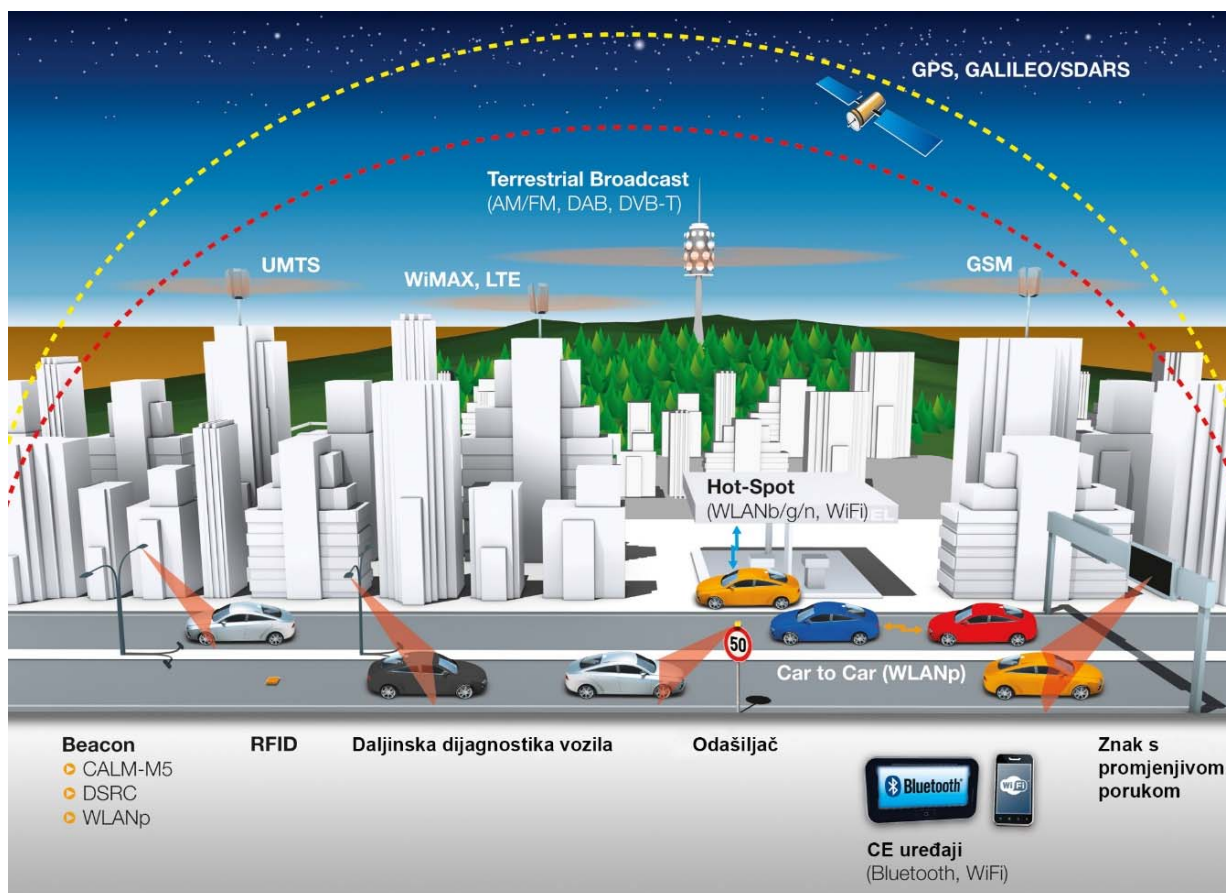
U ad hoc domeni dva ili više RSU-a mogu komunicirati direktno ili putem multihop veze na način korištenja istog protokola za usmjeravanje između OBU-a i RSU-a.

OBU može biti opremljen i s drugom bežičnom komunikacijskom opremom i spajati se s internetom preko pristupnih točaka u javnom, privatnom ili komercijalnom vlasništvu. Za razliku od OBU gdje se internetski pristup ostvaruje putem pristupnih točaka u slabije

⁹ Širokopojasni bežični radiokomunikacijski protokol kratkog dometa.

kontroliranom okruženju, kod RSU-a je pristup internetu obično postavljen kao strogo kontrolirani proces sa strane cestovne administracije ili uprave za ceste.

U slučajevima kada pristup internetu nije osiguran ni pomoću RSU-a niti pomoću pristupnih točaka OBU može koristiti komunikacijske mogućnosti mobilnih radiomreža (WiMAX, 4G, ...) ako su njezin sastavni dio.



Slika 14. C-ITS sustav (Copyright © 2009 - 2012 European Business Press SA)

4.1.1. Komponente sustava

U ovom se dijelu opisuju komponente sustava koje čine osnovu C2C komunikacijske arhitekture. Opisane komponente mogu djelovati na različite načine, a u osnovi se u praksi pojavljuju dvije različite konfiguracije: osnovna i proširena. Osnovna se konfiguracija sastoji od minimalnog skupa funkcionalnosti potrebnih za podršku sigurnosti kooperativnih aplikacija, dok je proširena nadograđena ostalim funkcionalnostima i služi za različita područja primjene.

4.1.1.1. Aplikacijska jedinica

Aplikacijska jedinica (AU) predstavlja entitet u vozilu koji pokreće aplikacije i koristi komunikacijske sposobnosti OBU-a. Ove sklopovsko-programске jedinice mogu biti sigurnosne aplikacije koje upozoravaju korisnika na opasnost, navigacijski sustavi s komunikacijskim svojstvima ili izdvojeni uređaji kao što su dlanovnici, mobilni telefoni i sl. koji pokreću internetske aplikacije.

AU može biti ugrađena u vozilo i trajno spojena s OBU što osigurava stalno izvršavanje minimalnog osnovnog skupa aplikacija u vozilu. Također, drugi tip AU-a može se dinamički spajati na mrežu u vozilu poput putničkih dlanovnika i mobilnih uređaja. U trenutku spajanja na OBU takvi uređaji bi se trebali automatski konfigurirati i nakon uporabe ukloniti (npr. nakon izlaska putnika iz vozila).

Predviđa se da će novi AU koristiti IPv6 uz zadržavanje podrške za IPv4 zbog starih prijenosnih AU-a. Također, zbog mogućnosti da istu raspoloživu informaciju, dobivenu putem osjetila u vozilu ili drugih čvorova, zatraži više aplikacija istovremeno, sustav to treba omogućiti putem određenog upravljačkog programa u vozilu.

4.1.1.2. Jedinica u vozilu

Jedinica u vozilu (OBU) je odgovorna za C2C i C2I komunikaciju, te pruža komunikacijske usluge AU-a i prosljeđuje informacije drugih OBU-a u ad hoc domeni. Svaki OBU je opremljen najmanje jednim mrežnim uređajem za bežičnu komunikaciju kratkog dometa koja se temelji na IEEE 802.11p. Osnovna mu je zadaća slanje, primanje i prosljeđivanje podataka koji se odnose na sigurnost u ad hoc domeni. Za ostale vrste podataka OBU može biti opremljen i drugim mrežnim uređajima koje se temelje na drugim radiotehnologijama poput 802.11a/b/g/n.

OBU funkcije i procedure uključuju bežični radiopristup, geografsko ad hoc usmjeravanje, upravljanje mrežnim zagušenjima, pouzdan prijenos poruka, sigurnost podataka, podršku za IP mobilnost, itd. Osnovni komunikacijski C2C sustav na OBU-u sadrži minimalni skup sigurnosnih aplikacija, C2C stog komunikacijskih protokola s C2C komunikacijskim transportnim i mrežnim slojem, radioprotokole s IEEE 802.11p uređajem i sučelje prema osjetilima u vozilu. Potencijalna proširena konfiguracija uključuje i druge sigurnosne i nesigurnosne aplikacije te opcionalna mrežna sučelja.

4.1.1.3. Jedinica u cestovnoj infrastrukturi

Jedinica u cestovnoj infrastrukturi (RSU) je fizički uređaj smješten na fiksnu lokaciju duž ceste ili autoceste, odnosno na lokaciji posebne namjene poput benzinske postaje, parkirališnih mjesta i restorana. RSU je obavezno opremljena s mrežnim uređajem za

bežičnu komunikaciju kratkog dometa koja se temelji na 802.11p. Da bi se mogla spojiti i komunicirati s infrastrukturnom mrežom RSU je redovito opremljena i s drugim mrežnim uređajima.

Osnovne funkcije RSU-a su:

- proširenje komunikacijskog opsega ad hoc mreže na način da prosljeđuje informacije nekog OBU-a prilikom njegovog ulaska u zonu komunikacijskog dosega RSU-a;
- pokretanje sigurnosnih aplikacija poput C2I upozorenja (npr. radovi na prometnici), upravljanja raskrižjima, virtualnih prometnih znakova i sl. RSU predstavlja istovremeno izvor informacija i sustav za prijenos, odnosno primanje i odašiljanje informacija;
- pružanje mogućnosti spajanja na internet za OBU koji se nalaze u komunikacijskom dosegu.

Osnovna konfiguracija RSU-a ima mogućnost samo prosljeđivati informacije, dok proširena konfiguracija uključuje i ostalu funkcionalnost.

4.1.2. Tehnički preduvjeti i ograničenja

Komunikacijski sustavi kao dio C-ITS moraju vozilu i vozaču garantirati čim viši stupanj anonimnosti i ne smiju ugrožavati njegovu privatnost. Oni bi u najmanjoj mogućoj mjeri zaštite morali pružiti makar razinu zaštite koju danas posjeduju korisnici mobilnih uređaja. Jedan od pristupa koji predlaže C2C konzorcij je da se koriste privremeni identifikatori umjesto fiksnih.

U europskim se zemljama privatnost različito tretira i regulira pa C2X sustavi moraju zadovoljiti cijeli niz različitih uvjeta kako bi osigurali prihvatljivu razinu anonimnosti i sigurnosti diljem Europe.

Vrlo značajan preduvjet uspješnosti sustava zasigurno je i nemogućnost slanja ili primanja pogrešnih ili lažnih podataka uslijed neispravnosti dijela sustava ili nastojanja zlonamjernih korisnika da utječu na sustav. Sustav mora biti pouzdan i imati visoku raspoloživost kako bi korisnici imali povjerenja u njegove mogućnosti. Višestruko pojavljivanje pogrešaka uzrokovalo bi neprihvatanje sustava od sve većeg dijela korisnika čije bi se povjerenje teško ponovno moglo pridobiti, a pogrešne i beskorisne poruke mogle bi izazvati promjenu ponašanja vozača i potencijalno ugroziti njegovu sigurnost ili rezultirati nezgodom. Jedna od mogućnosti je uvođenje digitalnih potpisa i certifikata te povećavanje razine otpornosti na greške uporabom odgovarajućih algoritama premda je nejasno ako se nesreća ipak dogodi tko će za nju preuzeti odgovornost, odnosno tko je za istu odgovoran.

C2X komunikaciju mora odlikovati robusnost pogotovo u slučajevima sigurnosnih aplikacija. Osiguravanje određene razine uslužnosti, odnosno minimalnog kašnjenja i maksimalne pouzdanosti pri slanju, primanju i prosljeđivanju poruka, jedna je od nezaobilaznih karakteristika C2X komunikacije. Tu karakteristiku nije moguće ostvariti ako se frekventni pojas dijeli s aplikacijama koje nisu sigurnosne naravi i koriste značajan udio raspoložive propusnosti pa se mora koristiti drugi frekvencijski pojas. Iako su kritične sigurnosne poruke relativno male (najčešće oko 100 B) i brzo se razmjenjuju (<100 ms), te su potaknute određenim događajem, one moraju stići do svih prijammnika na vrijeme bez obzira ako se u isto vrijeme u okolnim vozilima intenzivno koristi veliki dio raspoložive komunikacijske opreme (npr. za skidanje muzike i filmova ili korištenja drugih oblika zabave). Takvu kvalitetu i robusnost ne mogu osigurati otvoreni frekventni pojasevi poput ISM-a (*Instrumentafion, Scienfific and Medical*) pa se stoga predlaže alociranje učinkovito zaštićenog frekvencijskog pojasa. C2C konzorcij predlaže da taj pojas bude smješten između 5,885 i 5,905 GHz.

Očekuje se da C-ITS rade u svim okolnostima na prometnicama. Oni moraju osigurati neprekidnost komunikacije i u slučajevima vrlo visoke gustoće prometa i u slučajevima vrlo male gustoće prometa ili malog broja vozila s ugrađenom odgovarajućom opremom. Uz skalabilnost sustava neophodno je osigurati i očekivanu kompatibilnost između različitih proizvođača i generacija uređaja.

Ugradnja i integracija odgovarajuće komunikacijske opreme u vozila u domeni je proizvođača vozila i njihovih dobavljača, ali oni ipak moraju zadovoljiti određene preduvjete. Prije svega to je raspoloživost osnovnog skupa podataka od pripadajućih osjetila u vozilu te kvaliteta i sigurnost.

Struktura podataka i određeni skup karakteristika mora se unaprijed odrediti za obvezne podatke osjetila u sustavu. Primjer takvih podataka su podaci o poziciji vozila. Preciznost koja je potrebna komunikacijskom sustavu na razini je one u većini današnjih uređaja koji su opremljeni GPS-om, no dio aplikacija može trebati i veću preciznost ili učestaliju informaciju o poziciji. Također, pozicijski sustav ne mora biti obvezno GPS već se u tu svrhu može koristiti bilo koji sličan sustav.

C2C konzorcij se obavezao odrediti strukturu podataka koju će morati podržavati svi tipovi sustava u svim vozilima, a prvi prijedlog takvih podataka i parametara koje moraju pružiti osjetila u vozilu putem odgovarajućih sustava uključuje [121]:

- poziciju
- brzinu vozila

- smjer vožnje
- signale upozorenja na opasnost
- usporavanje vozila / snagu kočenja
- ABS, ESP i ASR¹⁰ podatke
- stanje brisača / osjetilo kiše.

Navedena lista će se po potrebi dopunjavati ovisno o potrebama aplikacija i odlučivat će se u kojoj mjeri će predloženi podaci osjetila biti obvezni.

4.2. Komunikacija u kooperativnim sustavima

Ovisno o području primjene C-ITS koriste uglavnom dvije bežične tehnologije: komunikacijsku tehnologiju kratkog dometa IEEE 802.11p i mobilnu mrežu treće generacije (3G), odnosno njezinom nadogradnjom pod nazivom dugoročna 3G evolucija ili 3.9G (*long-term evolution*, LTE)¹¹. Dok mobilne mreže ovise o centraliziranoj mrežnoj topologiji u kojem sav podatkovni promet prolazi kroz bazne stanice, IEEE 802.11p se ne temelji na pristupnim točkama već na direktnoj komunikaciji ITS stanica koje formiraju VANET. Fiksne ITS stanice poput pojedinih inteligentnih semafora pružaju uslugu pokretnim ITS stanicama (npr. vozilima) iako zapravo ne predstavljaju pristupne točke.

C-ITS aplikacije mogu se grubo podijeliti na aplikacije orijentirane na sigurnost cestovnog prometa (npr. upozorenja o promjeni prometnog traka, prilaz vozila žurnih službi, zaustavljena vozila na prometnici, promijenjeni uvjeti na cesti i radovi na cesti), aplikacije orijentirane na učinkovitost cestovnog prometa (npr. poboljšanje cestovnog prometnog toka, smanjenje emisije štetnih plinova i zagađenja uz pomoć optimizirane prometne signalizacije, signalizacije u vozilu i sustava za navođenje) i servise s dodanom vrijednosti (npr. najave komercijalnog tipa poput oglašavanja hotela, benzinskih postaja, trgovina i sl.) [122]. Aplikacije za sigurnost cestovnog prometa imaju stroge zahtjeve u pogledu

¹⁰ Sustav za sprječavanje blokiranja kotača (*Anti-lock braking system*), elektronički program stabilnosti (*Electronical stability program*) i sustav za upravljanje proklizavanjem (*Antriebschlupfregelung*).

¹¹ Dvije su osnovne tehnologije mobilne telefonije treće generacije (3G) i to: Universal Mobile Telecommunications System (UMTS) i Code Division Multiple Access 2000 (CDMA2000). Tehnologija se nadalje razvija u High-Speed Downlink Packet Access (HSDPA), odnosno 3.5G, High-Speed Uplink Packet Access (HSUPA), odnosno 3.75G te Worldwide Interoperability for Microwave Access (WiMAX) i prve LTE inačice odnosno 3.9G ili pre-4G. Wimax2 i napredni LTE predstavnici su 4G mobilne telefonije, a u istraživačkim se krugovima već duže vrijeme spominje 5G mreža čiji je razvoj započela NASA.

ograničenog kašnjenja i visoke pouzdanosti. Grupa protokola koja je dodijeljena za podršku ovakvom tipu aplikacija razvijana je u Europi i SAD-u. Glavni kandidati za navedeno područje primjene su 802.11p i jednostavni brzi mrežni transportni protokoli. Aplikacije za učinkovitost cestovnog prometa i servisi s dodanom vrijednosti mogu koristiti 802.11p i/ili 3G/LTE tehnologije s mrežnim protokolom koji podržava internetsku vezu (*Internet protocol version 6, IPv6*). Ne postoji stroga granica između aplikacija za sigurnost cestovnog prometa i učinkovitost cestovnog prometa. Ako se na cesti dogodi incident napredni sustav za navođenje može savjetovati vozače da koriste alternativnu rutu prije nego dođu do mjesta nesreće i završe u redu čekanja bez mogućnosti okretanja. Dakle, aplikacija za sigurnost cestovnog prometa sprječava vozače da nalete na zaustavljeno vozilo, a aplikacija za učinkovitost cestovnog prometa osigurava vozače od bespotrebnog trošenja vremena u redu čekanja na raščišćavanje nastale situacije.

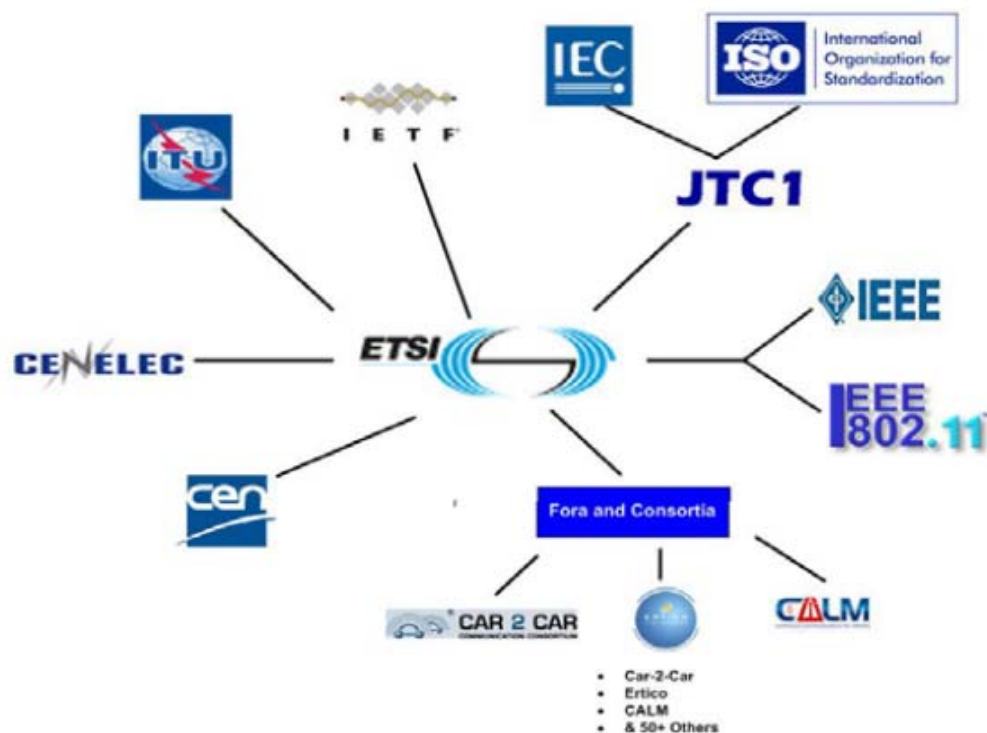
Različite C-ITS aplikacije imaju i različite komunikacijske zahtjeve. Jedna od osnovnih prednosti 802.11p norme je da se ne oslanja na pokrivenost pristupnim točkama ili baznim stanicama kako bi distribuirao informacije lokalno oko ITS stanice. Informacije se mogu slati i usmjereno u određenom smjeru koristeći geografsko navođenje. Uporabom IEEE 802.11p norme kašnjenje može biti manje jer nije potreban obilazak preko najbliže bazne stanice. Stoga, C-ITS aplikacije koje ne zahtijevaju mala kašnjenja ili distribuiraju informacije na regionalnoj razini, a ne na lokalnoj, mogu koristiti 3G/LTE za širenje servisnih informacija okolnim vozilima.

4.2.1. Norme i akronimi

Normiranje prometne komunikacije počinje 1999. godine kada Američka savezna komisija za komunikacije (*U.S. Federal Communications Commission, FCC*) dodjeljuje pojas od 75MHz (između 5,850 i 5,925 GHz) za ITS aplikacije kako bi se unaprijedila sigurnost putnika, smanjila prometna zagušenost, olakšalo smanjivanje zagađenja zraka i pomoglo očuvati vitalna fosilna goriva. Američko udruženje za testiranje i materijale (*American Society for Testing and Materials, ASTM*) prvo je izradilo normu za bežičnu lokalnu područnu mrežu 802.11, a zatim je malo prilagodilo kako bi više odgovarala jako brzim prometnim okruženjima. Norma ASTM E2213-03 bila je odobrena 2003. godine i sadržavala je aplikacijski, podatkovni i fizički sloj.

Nedugo zatim Institut za električno i elektroničko inženjerstvo (*Institute of Electrical and Electronics Engineers, IEEE*) preuzima posao od ASTM-a i stvara 802.11p radnu skupinu. Radna skupina proširuje protokol novim slojevima kako bi podržala internetski pristup i čini ga više holističkim, te ga naziva bežični pristup za prometno okruženje (*wireless access in vehicular environment, WAVE*).

Da bi se označio IEEE 802.11p ili ad hoc dio WAVE arhitekture često se koristi izraz namjenski komunikacijski protokol kratkog dometa (*dedicated short-range communication*, DSRC). Frekventni pojas kojeg koristi DSRC razlikuje se u Europi, Americi i Japanu, ali u osnovi služi za komunikaciju kratkog dometa između jedinice u vozilu (*On Board Unit*, OBU) i infrastrukturne jedinice (*Road Side Unit*, RSU) i najčešće se primjenjuje u javnom prijevozu, upravljanju parkiranjem i naplati cestarine.



Slika 15. Odnosi između normativnih tijela [123]

Međunarodna organizacija za normiranje (*International Organization for Standardization*, ISO) pokrenula je inicijativu i razvila okvir pod nazivom komunikacijski pristup za zemaljske mobilne uređaje (*communications access for land mobiles*, CALM). Osnovna je ideja da se iskoriste svi postojeći tipovi bežičnih pristupnih tehnologija kao što su 2G/3G/LTE, bežični širokopojasni pristup (npr. WiMAX), Wi-Fi, IR i IEEE 802.11p te pružanje djelotvornih bežičnih veza krajnjim korisnicima i aplikacijama. Unutar CALM norme, IPv6 protokol služi kao konvergencijski sloj između različitih komunikacijskih medija i tipova aplikacija. VANET podrška ostvarena je kroz CALM M5 normu koja se temelji na IEEE 802.11p. Međutim, sve ITS aplikacije nisu u mogućnosti koristiti IPv6 zbog okruženja koje se brzo mijenja.

Godine 2007. Europski institut za telekomunikacijske norme (*European Telecommunications Standards Institute*, ETSI) uspostavlja Tehnički odbor za ITS (TC) koji je odgovoran za daljnje donošenje normi u Europi za odnosnu skupinu protokola. Europska komisija 2009. godine

dodjeljuje mandat M/453 službeno prepoznatim europskim organizacijama za normizaciju: Europskom odboru za normizaciju (*European Committee for Standardization*, CEN), Europskom odboru za elektrotehničke norme (*European Committee for Electrotechnical Standardization*, CENELEC) i Europskom institutu za telekomunikacijske norme. Navedene su organizacije pozvane pripremiti set normi, specifikacija i vodiča za podršku provedbe i razvoja kooperativnih inteligentnih transportnih sustava u okvirima Europske zajednice. Suradnja europskih i međunarodnih normativnih tijela prikazana je na slici 15.

U Europi se 30 MHz (od 5,875 do 5,905 GHz) isključivo namjenjuje za aplikacije sigurnosti cestovnog prometa, dok se ostala prometna komunikacija usmjerava na pojas od 20 MHz (od 5,855 do 5,875 GHz). Dodijeljeni frekvencijski pojasevi dijele se na 10 MHz frekvencijske kanale, a uslijed neposredne blizine ovih pojaseva frekvencijskom pojasu koji se u Europi koristi za elektroničku naplatu cestarine (5,795–5,805 GHz) ETSI TC ITS mora razviti tehnologije za izbjegavanje interferencija s CEN-DSCR sustavima. Svi navedeni frekventni pojasevi su besplatni za uporabu.

Prvi set normi za C-ITS CEN i ETSI dostavljaju u veljači 2014. godine. One će omogućiti vozilima različitih proizvođača da u budućnosti komuniciraju kako međusobno tako i sa sustavima koji su dio cestovne infrastrukture.

4.2.2. Distribuirano upravljanje zagušenjima u komunikaciji

Prva tehnologija koju je normirao ETSI TC ITS nazvana ITS-G5 zasniva se na IEEE 802.11p s posebnim zahtjevima usmjerenim na distribuirano upravljanje zagušenjima (*distributed congestion control*, DCC). DCC predstavlja skupinu metoda čiji je zadatak upravljati mrežnim opterećenjem kako bi se izbjegla nestabilnost. Metoda sloja za pristup mediju (*Medium Access Layer*, MAC) koju koristi IEEE 802.11-2012 sastoji se u višestrukome pristupu s osluškivanjem nosioca (*Carrier sense multiple access*, CSMA). Ova se MAC metoda suočava s problemom prijenosa u ad hoc načinu rada kada se gustoća stanica poveća. Istovremeni prijenos podataka će se tada prije dogoditi u geografski bližim ili kolociranim stanicama (onima koje su u radiodosegu jedna od druge). DCC je način na koji se ovaj problem može riješiti. Svaka stanica nadgleda aktivnosti u kanalu i kada se razina aktivnosti poveća iznad unaprijed određene granice zauzeća, poduzimaju se mjere za izbjegavanje nestabilnosti.

4.3. ICSI arhitektura sustava

ICSI arhitektura sustava oslanja se na prethodno opisanu C-ITS arhitekturu i poput većine inteligentnih transportnih sustava sastavljena je od četiriju osnovnih podsustava:

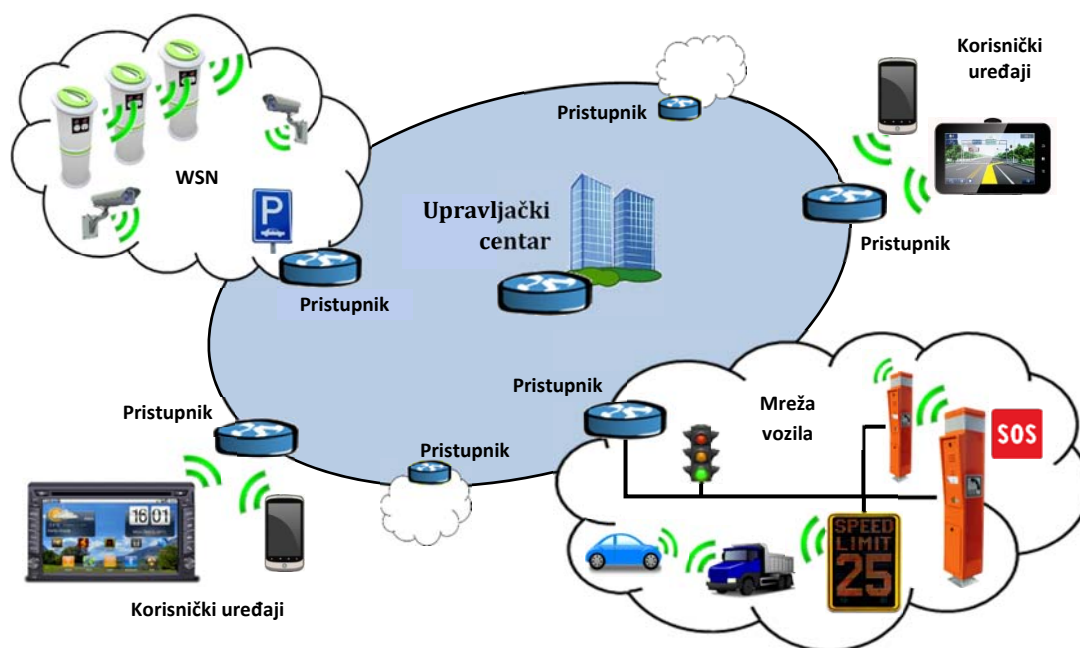
- Centralnog podsustava (CS) – centar za upravljanje prometom prikuplja informacije od mjerodavnih prometnih dionika (tijela nadležnih za cestovni promet, operatera cestovnog prometa i sl.), meteoroloških postaja, regionalnih središta za prikupljanje podataka i mjernih točaka na prometnici. Informacije se analiziraju i donose odluke koje se prenose nazad do signalizacijskih uređaja na prometnoj infrastrukturi. Nedostatci centraliziranog pristupa, koji ne može postići zadovoljavajuće stvarnovremensko djelovanje, kod distribuiranog ICSI sustava se otklanjaju upotrebom autonomnih pristupnika u sklopu kojih se već provodi analiza prikupljenih podataka i određuju najbolje prometne strategije, a centralni podsustav najčešće služi kao izvor povijesnih podataka kojima se pospješuje djelovanje inteligentnih algoritama. Na taj se način osigurava stvarnovremensko upravljanje prometom koje se temelji na decentraliziranoj agregaciji prometnih informacija dobivenih od cestovne infrastrukture.
- Cestovnog podsustava (RS) – čine ga RSU (osjetila, aktuatori, itd.) i oprema u vozilu. RSU se sastoje od autonomnih ugradbenih uređaja koji su zaduženi za izdvajanje određenih ITS parametara (npr. broja vozila na cestovnoj dionici ili broja raspoloživih parkirališnih mjesta) ili utječu na ITS parametre ovisno o okolini. Oprema u vozilu koristi dvosmjerne komunikacijske kanale kako bi razmijenila informacije s RSU-om u istom RS-u ili drugim RS-ovima i OBU-ima unutar VS-a. ICSI osjetila i aktuatori predstavljaju M2M uređaje¹² i podržavaju propisanu M2M arhitekturu [123] te na taj način aplikacije u tim uređajima komuniciraju s pristupnikom i njegovom aplikacijom.
- Podsustava u vozilu (VS) – sadrži OBU koji pokreće M2M uređaj. Bez obzira predstavlja li podsustav parkiranog ili vozila u pokretu, VS komunicira s M2M uređajem pristupnika koji je dio RS-a. M2M aplikacija koja radi na M2M uređaju u VS-u uglavnom se koristi za pristup ITS uslugama sigurnosti, ugodnosti i učinkovitosti vožnje. Osnovne VS komponente sukladno ISCI projektu su: procesorska jedinica, sučelje prema aktuatorima za upravljanje motorom vozila, sučelje između vozača i ITS usluga, mobilna širokopojasna oprema i pozicijski sustav.

¹² M2M (*machine to machine*) tehnologija predstavlja automatsko podatkovno povezivanje uređaja ili strojeva, odnosno aplikacija različitih namjena u svrhu nadgledanja i kontrole njihovog rada.

- Osobnog podsustava (PS) – mobilni uređaji koje koriste vozači ili pješaci u svrhu prikupljanja mobilnih informacija ili pristupa različitim uslugama putem WiFi ili 3G/4G internetske veze. Sukladno ETSI M2M arhitekturi, PS je uređaj s odgovarajućom aplikacijom koji je direktno spojen na ICSI pristupnik.

ICSI sustav sa svim podsustavima se zasniva na mrežama vozila i WSN-u što ga čini prikladnim za prikupljanje i obradu velike količine osjetilnih podataka na pouzdan način i s mogućnostima daljnjeg proširivanja. Stoga navedeni sustav čine raznovrsne komponente (vidi sliku 16.) [123]:

- upravljački centar – prikuplja, pohranjuje i obrađuje velike količine podataka koje pristižu od ostalih komponenata sustava, osigurava sigurnost i održava učinkovitost sustava;
- RSU – smještene uzduž prometnica za prikupljanje vrijednosti različitih mjernih veličina putem odgovarajućih osjetila (poput osjetila prometnog toka, parkirališnih osjetila, itd.), pokretanje izvršnih uređaja s povratnom spregom (poput VMS-a ili mjesta za punjenje električnih vozila) i spajanje na internet pri čemu djeluju kao pristupnici (*gateway*, GW)¹³;



Slika 16. Komponente sustava

¹³ Uređaj ili aplikacija koja spaja dvije komunikacijske mreže koje koriste različite protokole.

- OBU – smještene u vozilima i opremljene uređajima za bežično umrežavanje koji osiguravaju V2X komunikaciju u mrežama vozila, a mogu se opremiti i različitim osjetilima. Prema potrebi mogu se opremiti i s internetskom vezom koja se ostvaruje putem mobilnih mreža kako bi rasteretile RSU;
- korisnički uređaji – korisnička oprema koja se sastoji od prijenosnih uređaja poput tableta, pametnih mobilnih telefona, itd., a koriste je pješaci i vozači, odnosno putnici koji su uključeni u prikupljanje novosti, putnih i drugih oblika informacija.

Osjetilni podaci obrađuju se na kooperativan način već na najnižoj razini i u najranijoj fazi, npr. informacija o prometnom toku može se prikupiti putem WSN-a čiji se rad temelji na jeftinoj kameri koja radi kao osjetilo i pohraniti lokalno te se u upravljački centar šalje samo statistički podatak koji je rezultat dugotrajnog vrednovanja. U tu svrhu ICSI određuje dva ključna koncepta:

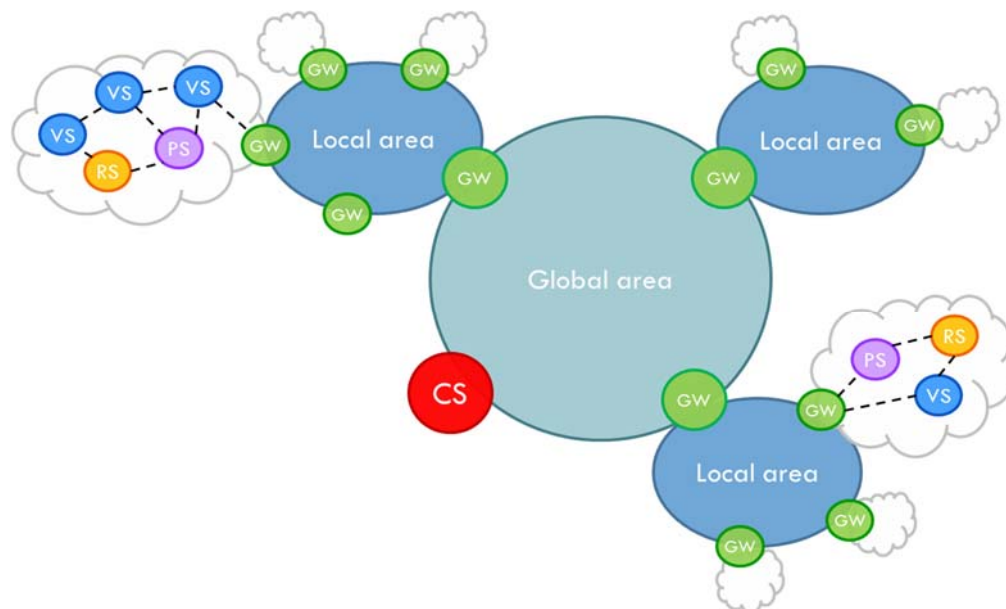
- pristupnik – fizički entitet koji je dio RSU ili upravljačkog centra i omogućava im spajanje na određeno područje
- područje – sastavljeno od jednog ili više pristupnika s odgovarajućom komunikacijom i unaprijed postavljenim kriterijima za uspostavljanje krajnjih granica djelovanja (npr. gustoća stanovništva ili prometa).

ICSI referentni model koristi lokalno pohranjivanje podataka i inteligenciju koji djeluju na ograničenom geografskom području i gdje su podaci obrađeni i distribuirani u stvarnom vremenu bez potrebe za uspostavljanjem veze s CS. U tu se svrhu uvodi pristupnik koji kao svojevrsni logički entitet pruža mogućnosti jednake onima koje se obično realiziraju putem CS-a (npr. obrada događaja i alarmiranje). Svaki je GW spojen s nizom RS, VS i PS, odnosno, logički je spojen na:

- CS, u svrhu agregacije podataka za dugotrajne optimizacije ili druge statističke primjene
- GW u istom području, koji upravlja podacima osjetila i aktuatora za koje je nadležan
- GW izvan njegovog područja, u slučaju događaja koji se odražava na šire područje (npr. zagušenja koje može imati kaskadni učinak na više ograničenih područja).

Veza s drugim pristupnicima ostvaruje se samo prema potrebi na modelu pretplate. Samo područje ne odražava fizičku već logičku cjelinu pa isti GW može istovremeno pripadati u više lokalnih područja ovisno o procesorskoj snazi, memorijskom prostoru i prostoru za pohranjivanje podataka. Veličina područja određena je još i gustoćom stanovništva, prometa i informacijsko-komunikacijskih elemenata.

Na slici 17. prikazana je logička ICSI arhitektura koju sačinjavaju tri lokalna područja. Svako lokalno područje logički je povezano s globalnim podržavajući međusobnu komunikaciju koja se fizički ostvaruje putem interneta ili sporednih veza. Lokalni podaci spremaju se na GW lokalnog područja koji na osnovi istih donosi odgovarajuće odluke. Stvarnovremenska obrada podataka i upravljanje usredotočeni su uglavnom na podatke iz neposredne prošlosti pa se sukladno tome na GW-u i čuvaju jedino oni dok se ostatak prenosi CS-u.



Slika 17. Logička ICSI arhitektura

Osnovne komponente ICSI referentnog modela su:

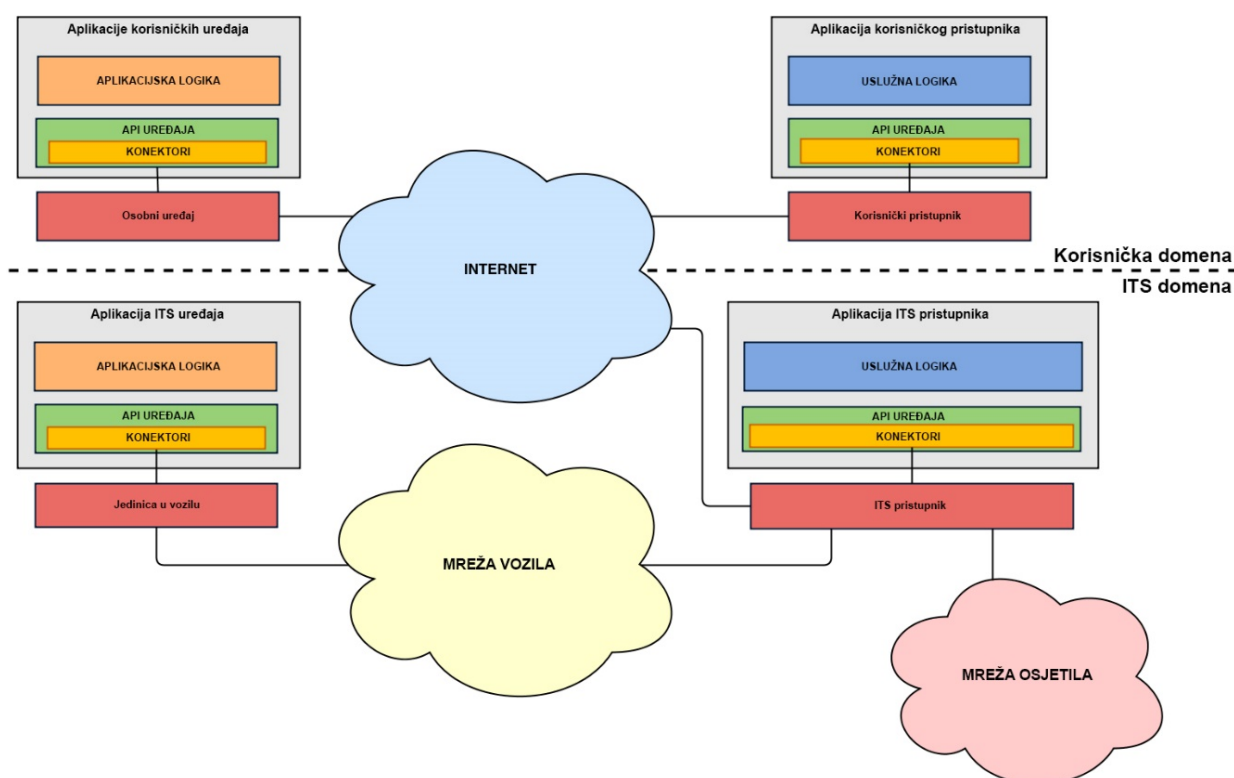
- domenski model
- funkcionalni model
- komunikacijski model
- informacijski model
- sigurnosni model.

4.3.1. Domenski model

ICSI se može podijeliti u dvije domene kako je prikazano na slici 18.:

- ITS domenu – sastavljena je od aplikacija i poslovne logike koja se odnosi na kooperativnu inteligenciju (npr. kooperativno učenje) i ima za cilj:
 - sigurnost
 - održivost

- smanjenje prometnih zagušenja
 - upravljanje prometom
 - nadzor prometa
 - simulaciju prometa
 - predviđanje prometa.
- korisničku domenu – sastavljena je od aplikacija i poslovne logike koja se odnosi na usluge.



Slika 18. Domenski ICSI model

ICSI sustav se sastoji od pet osnovnih entiteta:

- podsustava (CS, RS, VS i PS)
- pristupnika (GW) – razlikuju se dva tipa pristupnika:
 - ITS pristupnik s pripadajućom aplikacijom koja pokreće uslužnu logiku i podržava distribuciju ICSI kooperativne inteligencije. Komunikacija između ITS pristupnika, bežičnih mreža osjetila i mreža vozila ima za cilj postizanje više razine sigurnosti, osiguravanje održivosti i smanjivanje zagušenja.

Aplikacija ITS uređaja nalazi se u sklopu OBU-a i preko ITS pristupnika koji je dio RS-a prima potrebne informacije.

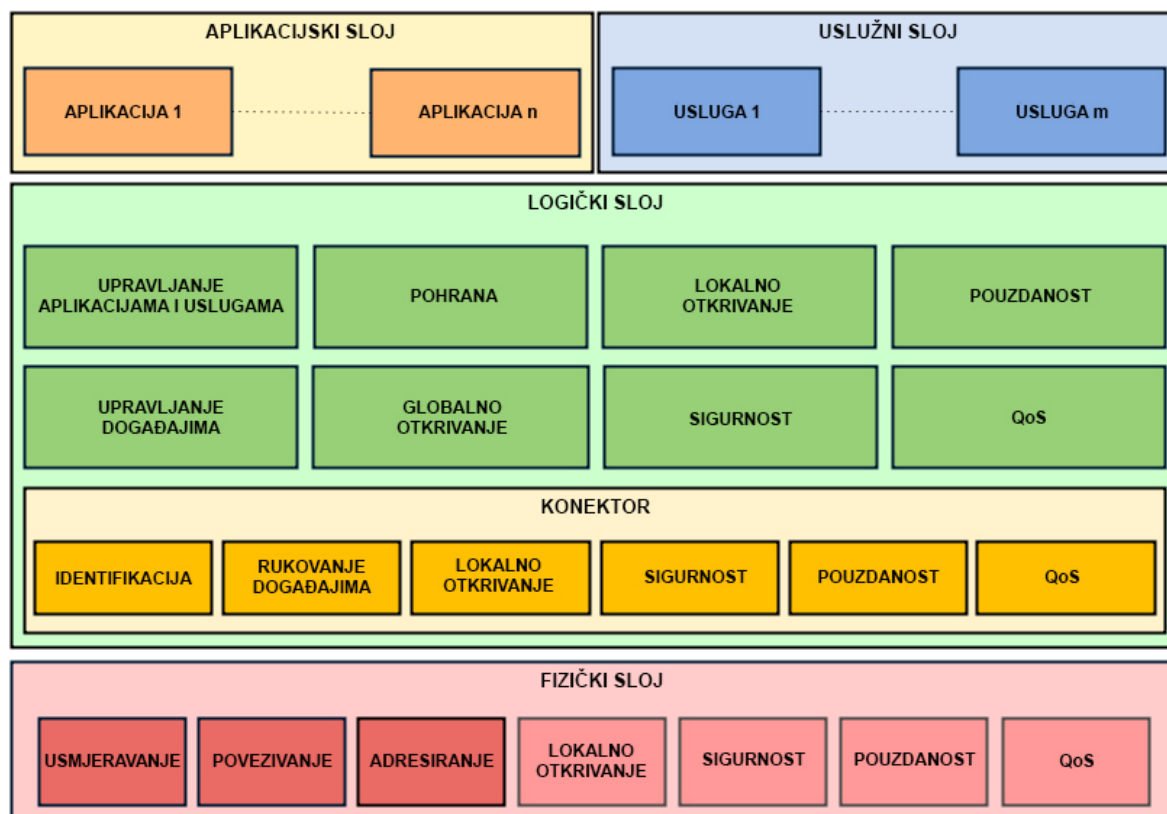
- korisnički pristupnik s pripadajućom aplikacijom koja pruža širi skup usluga uz pomoć uslužne logike. Korisničke usluge, poput prijenosa videa ili naplate parkiranja, nisu ograničene uvjetima sigurnosti i održivosti kao u prethodno navedenom slučaju i pristupa im se putem aplikacija korisničkih uređaja koje se pokreću na osobnim uređajima ili OBU-ima opremljenim internetskom vezom.
- uređaja – korisnički ili ITS uređaji koji mogu pokretati aplikacije korisničkih ili ITS uređaja respektivno.
- aplikacija – aplikacije pristupnika, koje su smještene na pristupnicima i oslanjaju se na uslužnu logiku kako bi pružile usluge i informacije ostalim uređajima i aplikacijama pristupnika, i aplikacije uređaja, koje koriste usluge aplikacija pristupnika i prikazuju informacije koje im se tim putem prosljeđuju na svojem grafičkom sučelju.
- područja – globalna i lokalna. Distribuirano izvršavanje usluga omogućeno je putem međusobno spojenih pristupnika. U logičkom je sloju sažeta kooperativna priroda sustava pa je moguće lokalno obrađivati događaje, koji pristižu od WSN-ova, mreža vozila ili drugih pristupnika, i stvarati izlazne rezultate transparentno postižući kooperativnost.

4.3.2. Funkcionalni model

Funkcionalni ICSI model predstavlja slojevit arhitekturu podijeljenu u četiri osnovna sloja:

- aplikacijski sloj
- uslužni sloj
- logički sloj
- fizički sloj.

Svakom sloju ili podsloju pripada određena grupa funkcionalnosti (slika 19.).



Slika 19. Funkcionalni ICSI model

Fizički sloj ICSI arhitekture može podržati različite postojeće ITS mreže i mreže za razmjenu podataka ako zadovoljavaju minimalni skup zahtjeva za funkcionalnošću. Obvezne funkcionalnosti su sljedeće:

- usmjeravanje – predstavlja osnovu za upravljanje mrežom i nadzor te usmjerava podatke koje razmjenjuju čvorovi unutar mreže
- povezivanje – osigurava osnovnu povezanost mrežnih čvorova
- adresiranje – koristi se za raspoznavanje uređaja pomoću identifikacije.

Opcionalne funkcionalnosti su:

- lokalno otkrivanje – odnosi se na postupke i procedure otkrivanja uređaja koji se spajaju na pristupnik putem WSN-a ili mreža vozila
- sigurnost – sadrži osnovne postavke sigurnosti koje se proširuju prema višim slojevima u skladu sa sigurnosnim modelom kako bi postigli sigurnu komunikaciju
- pouzdanost – odnosi se na uspostavljanje sigurne i pouzdane komunikacije
- QoS (*Quality of service*) – pruža podršku sigurnoj i pouzdanoj komunikaciji.

Logički sloj sadrži podsloj pod nazivom *konektor* koji služi za spajanje s ICSI entitetima fizičkog sloja. On omogućuje uslužnom i aplikacijskom sloju pristup različitim uređajima. Ovaj sloj koriste pristupnici kako bi ostali spojeni s drugim pristupnicima u danom području i transparentno pristupali uređajima ovisno o njihovoj lokaciji. Funkcionalnosti logičkog sloja su:

- upravljanje aplikacijama i uslugama – osigurava uvjete za dinamičko učitavanje aplikacija, daljinsku instalaciju i nadogradnju;
- upravljanje događajima – izlaže događaje višim slojevima putem konektora te određuje raspored i prioritete kojim ih usluge i aplikacije obrađuju;
- pohrana – određuje pravila za upravljanje trajnim podacima, prikuplja, pohranjuje i održava podatke unutar područja te ih čini pristupačnima na distribuirani način;
- globalno otkrivanje – otkriva druge pristupnike u istom ili različitom području. Usluga koja zahtijeva pristup određenom uređaju komunicira s logičkim slojem. Logički sloj pristupa uređaju putem konektora ako je on lokalno spojen, a u suprotnom se koristi funkcionalnost globalnog otkrivanja za lociranje istog;
- lokalno otkrivanje – putem konektora izlaže višim slojevima lokalno spojene uređaje;
- sigurnost – upravlja klasama sigurnosti na način da ih preslikava na osnovnu sigurnost koju pružaju konektori;
- pouzdanost – osigurava pouzdanu komunikaciju između ICSI pristupnika;
- QoS – osigurava klase, politike i procedure koje uslužni i aplikacijski sloj koriste na zahtjev unaprijed postavljenih QoS razina.

Uslužni sloj prima podatke od logičkog sloja pojavljivanjem odgovarajućeg događaja i obrađuje ih na osnovi ugrađene posebne uslužne logike. Usluge može pokrenuti jedino pristupnik.

Aplikacijski sloj sadrži aplikacije instalirane na ICSI uređajima koje mogu biti ITS aplikacije ili korisničke aplikacije.

4.3.3. Komunikacijski model

Komunikacijski stog ICSI komunikacijskog modela sličan je OSI referentnom komunikacijskom modelu¹⁴. ICSI komunikacijski model osigurava komunikaciju od pristupnika do pristupnika i od pristupnika do uređaja.



Slika 20. ICSI komunikacijski model

Model čini šest slojeva:

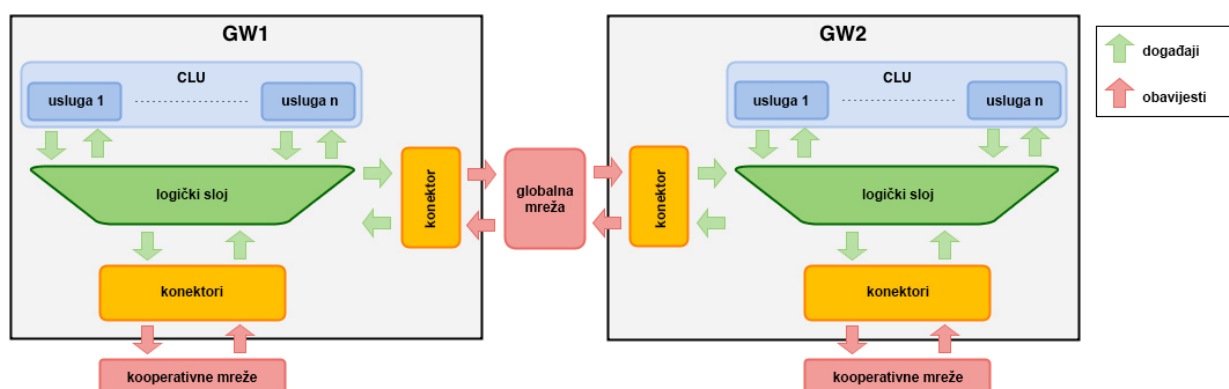
- fizički sloj – ima istu funkcionalnost kao fizički sloj OSI komunikacijskog modela
- sloj veze – ima istu funkcionalnost kao podatkovni sloj OSI komunikacijskog modela i uključuje najnovija tehnološka postignuća poput determinističkog sloja za pristup mediju (MAC) sloja

¹⁴ Referentni model za otvoreno povezivanje sustava (*Open Systems Interconnection*, OSI) je najčešće korišteni model za opisivanje arhitekture mreže. On dijeli arhitekturu mreže u sedam slojeva (fizički, podatkovni, mrežni, prijenosni, komunikacijski, prezentacijski i aplikacijski) i opisuje međusobne odnose uređaja, aplikacija, usluga i protokola pri mrežnim komunikacijama.

- mrežni sloj – ima istu funkcionalnost kao mrežni i prijenosni sloj OSI komunikacijskog modela
- harmonizacijski sloj – može pokrivati različite mreže, nositi se s njihovim raznolikostima i prilagođenim komunikacijskim shemama. Ovaj sloj pruža jedinstveno sučelje prema višim slojevima pa oni mogu identificirati priključene uređaje i pristupiti im na transparentan način bez obzira na osobine specifične mreže
- GW 2 GW – odgovoran je za unutrašnju i vanjsku komunikaciju među pristupnicima gdje se relevantni podaci razmjenjuju prema modelu „izdavač-pretplatnik“
- podatkovni sloj – nudi mogućnost nadzora i upravljanja podacima u skladu s ICSI informacijskim modelom.

4.3.4. Informacijski model

ICSI informacijski model zasnovan je na konceptu „događaja“ kako je prikazano na slici 21.



Slika 21. ICSI informacijski model

Kooperativne mreže mogu stvoriti obavijesti koje su direktni ili indirektni rezultat pojavljivanja određenih promjena u promatranim stanjima komunikacijske mreže poput razmjene podataka, kolebanja nadziranih parametara, itd. Konektori su sposobni raščlaniti te obavijesti u događaje koji imaju opću strukturu i semantiku.

Usluge primaju događaje koji dolaze od različitih konektora preko logičkog sloja, obrađuju ih i stvaraju izlazne događaje. Ovi izlazni događaji mogu zatim pokrenuti određenu uslugu i obradu na drugim pristupnicima, ostvarujući time kooperativnu inteligenciju, ili kooperativnoj mreži, rezultirajući obavijestima koje imaju utjecaj na određenu interesnu skupinu.

Pristupnici koji raspolažu skupom dinamičkih algoritama mogu pružati stvarnovremensko upravljanje prometom koje se temelji na decentraliziranoj agregaciji prometnih informacija dobivenih od cestovne infrastrukture. Distribuirano upravljanje prometom i nadzor ostvaruje se suradnjom između agenata na različitim razinama smještenim u podmodele određene ICSI arhitekturom. Navedeno će se ostvariti uz pomoć ugradbenih modula za podršku odlučivanju s kombinacijom neizrazite logike i neuronskih mreža koji će biti integrirani u jedinicu za kooperativno učenje (*Cooperative Learning Unit, CLU*).

4.3.5. Sigurnosni model

Sigurnosni model sadrži formaliziranu sigurnosnu politiku sustava na visokoj razini. Funkcionalni ICSI model se koristi da bi se opisala sva funkcionalna gledišta sustava sa stajališta sigurnosti. To uključuje sve učesnike i njihova moguća međudjelovanja. Sigurnosni model opisuje sigurnosne ciljeve dodijeljene svakom pojedinom sredstvu koje čini sustav ili djeluje u sklopu istog, kako bi se zaštitila njihova povjerljivost i integritet. U uskoj vezi s funkcionalnim modelom, ovaj model visoke sigurnosne razine zatim stvara pravila za niže razine sigurnosti (kontrola pristupa, upotreba posebnih vjerodajnica i sl.).

5. MODELI IZBORA RUTE

Izbor optimalne rute u velikim gradskim središtima ne može se zasnivati na poznavanju cjelokupnog transportnog sustava sa strane korisnika i jednostavnom odabiru najkraće rute u odnosu na prostor i vrijeme kao osnovnih čimbenika. Poznavanje prometa svakako utječe na izbor skupine ruta koje će korisnik uzeti u obzir prilikom izbora, no isti će ovisiti i o nizu vidljivih socioekonomskih varijabli i varijablama koje predstavljaju stavove korisnika.

Napredni sustavi za informiranje putnika koji koriste samo fiksne i dinamičke karakteristike prometne mreže relativno brzo su se pokazali kao nedovoljno zadovoljavajući usprkos činjenici da su nastojanja proizvođača sustava i pripadajućih razvojnih timova bila orijentirana u smjeru visokog zadovoljstva korisnika. Testiranje rutnih vodiča u vozilu na području grada Chicaga [124] otkrilo je značajno nezadovoljstvo korisnika s rutama koje su predložili algoritmi utemeljeni na tradicionalnim modelima planiranja prijevoza (npr. najkraće vrijeme putovanja). Ako ATIS predlaže rute samo na osnovi najkraćeg vremena putovanja, a putnici obično uz najkraće vrijeme putovanja u razmatranje uzimaju i druge čimbenike poput smanjivanja zahtjevnosti vožnje i sl., tada sustav ne sugerira putnicima najprivlačniju rutu. Stoga je zadatak naprednih algoritama predlaganje takvih ruta koje će biti više u skladu s mogućim ljudskim izborom, a time i puno bliže ATIS korisnicima i općenito učinkovitije.

Nakon prepoznavanja skupa izvodivih ruta putovanja potrebno je odrediti koje će rute razmatrati putnik prilikom procesa odlučivanja. Skup izbora tada predstavlja skup prebrojivih alternativa koje je putnik odabrao. Vjerojatnost predviđenog izbora je funkcija atributa svih alternativa iz pojedinog skupa izbora.

Modeliranje ponašanja pri izboru rute osnova su učinkovitosti sustava s rutnim vodičima i navigacijom. Njima se može procijeniti način na koji putnici opažaju karakteristike ruta, prognozirati ponašanje putnika u potencijalnim scenarijima, predvidjeti buduće uvjete u prometu na transportnim mrežama, te doprinijeti razumijevanju reakcije putnika i prilagodbu na dobivene informacije. Modeliranje ponašanja pri izboru rute je problematičan proces zbog složenosti predstavljanja ljudskog ponašanja, nedovoljnog poznavanja mrežne strukture od strane putnika, nejasnog načina na koji putnik doživljava karakteristike rute i izostajanja preciznih informacija o sklonostima putnika.

Modeli izbora rute ne predstavljaju samo pomoć u analiziranju i razumijevanju ponašanja putnika već se na njima temelje i metode za dodjeljivanje prometa. Problem u modeliranju može biti deterministički ili stohastički. U determinističkom problemu korisničke ravnoteže

(*deterministic user equilibrium*, DUE) jednostavan model izbora rute pretpostavlja savršeno znanje o troškovima puta i odabir rute koja minimizira troškove putovanja. U stohastičkom problemu korisničke ravnoteže (*stochastic user equilibrium*, SUE) model vjerojatnosti izbora rute pretpostavlja neimanje savršenog znanja o troškovima puta i svih neophodnih informacije, te se odabire ruta za koju se smatra da minimizira troškove putovanja. U simulacijama pri dinamičkom dodjeljivanju prometa (*Dynamic Traffic Assignment*, DTA) model izbora rute je unaprijed određen pri učitavanju mrežne strukture.

U nastavku se prikazuju različiti pristupi i tehnologije u okviru modeliranja diskretnih izbora. Sličan je pristup primjenjiv i u kontekstu parkiranja i multimodalnom kontekstu. Alternativni pristupi navedenoj problematici poput neizrazite logike (*fuzzy logic*) [125], [126], [127], umjetnih neuronskih mreža (*Artificial Neural Networks*) [128] i kognitivne psihologije [129], [130] u ovom se radu neće obrađivati.

5.1. Najkraći put

Najjednostavniji model izbora rute pretpostavlja želju korištenja rute s najmanjom vrijednošću jedne varijable poput udaljenosti ili vremena putovanja. Tako postavljen problem najčešće nosi naziv "problem najkraćeg puta" i obično se rješava Dijkstra algoritmom [131]. Prometno dodjeljivanje u kojem se sva putovanja nekog para ishodište-odredište učitavaju na najkraći put naziva se "sve ili ništa".

Upotreba algoritma najkraćeg puta također pretpostavlja svijest o svim rutama i pripadajućim troškovima koje će putnik koristiti.

5.2. Korisnička ravnoteža

Problem postaje puno složeniji kada se kao objektivna varijabla uključi i zagušenje vremena putovanja. Zagušenje vremena putovanja je funkcija prometnog volumena koji predstavlja ukupan broj prometnih entiteta koji prolaze mrežnom dionicom u jedinici vremena. Zagušenje vremena putovanja računa se prema izrazu koji se općenito koristi u aplikacijama za prometno planiranje¹⁵:

$$T_c = T_0 \left[1 + \alpha_{pt} \left(\frac{V}{C} \right)^{\beta_{pt}} \right] \quad (7)$$

¹⁵ U praksi se koristi cijeli niz različitih funkcija zagušenja koje se često nazivaju i V-D funkcijama (*volume-delay*). Funkcija koja se ovdje koristi je funkcija s vjerojatno najširoom primjenom, a dobila je naziv prema svom tvorcu, BPR funkcija [133].

gdje su:

T_c – zagušenje vremena putovanja na promatranoj prometnoj dionici

T_0 – vrijeme putovanja slobodnim tokom

V – prometni volumen u razdoblju od jednog sata

C – kapacitet (propusna moć) prometnice u razdoblju od jednog sata

α_{pt}, β_{pt} – parametri prometnog toka (obično $\alpha_{pt} = 0,15, \beta_{pt} = 4$).

U svrhu rješavanja problema najkraćeg puta ovisnog o toku prometa često se naizmjenično koristi iterativni pristup između najkraćih putova s fiksnim vremenima putovanja i preračunatim vremenima putovanja na osnovi novih prometnih volumena. Ravnoteža se uspostavlja između odabranih ruta koje su ovisne o vremenu putovanja i prolaznih vremena za određenu dionicu koja ovise o prometnom volumenu. Kada putnici koji nastoje smanjiti vrijeme putovanja nemaju namjeru mijenjati rute, iteracijski izračuni postižu stanje koje odgovara *Wardropovom prvom principu* [132]. Ovaj se princip može izraziti i na način da za svaki dani par ishodište-odredište vrijedi da sve korištene rute imaju isto vrijeme putovanja, a sve nekorištene rute imaju vrijeme putovanja veće ili jednako vremenu putovanja korištenih ruta. Naziv za situaciju opisanu prvim Wardropovim principom je upravo *korisnička ravnoteža*.

Drugi Wardropov princip opisuje situaciju u kojoj se smanjuje ukupno vrijeme putovanja u prometnoj mreži što se često naziva optimalno dodjeljivanje prometa sustavu. Da bi se ostvarilo optimalno dodjeljivanje prometa sustavu, putnike treba dodjeljivati prometnim dionicama na način da se uzimaju u obzir granični troškovi putovanja koje će proizvesti svaki dodatni putnik pridružen promatranoj dionici umjesto prosječnih troškova putovanja koji su indirektno opisani izrazom za izračunavanje zagušenja vremena putovanja (7). Marginalni su troškovi putovanja veći od prosječnih troškova putovanja zbog konkavnosti navedene funkcije.

Za rješavanje problema dodjeljivanja prometa ovisnog o prometnom toku koriste se općenito dvije metode i to: metoda konveksnih kombinacija (ili Frank-Wolfe algoritam) i metoda uzastopnih prosjeka (*Method of Successive Averages*, MSA).

Metoda konveksnih kombinacija [134] je postupak kojim se pomoću dekompozicije rješavaju problemi nelinearne optimizacije. Problem se transformira u linijski program i jednodimenzionalni nelinearni problem odnosno tzv. "traženje linije" (*line search*). Svaki korak linearnog programa naziva se "traženje smjera" (*direction finding*) jer predstavlja traženje novog izvodivog rješenja kojim se unaprjeđuje funkcija cilja. Svakom iteracijom

programa traži se prosjek između trenutnog rješenja traženja smjera i prethodnih rezultata, kako bi se odredio novi minimum funkcije cilja. Traženje smjera se provodi uporabom izračuna najkraće rute koristeći različite algoritme (poput Dijkstra algoritma). Ovu je metodu za rješavanje problema dodjeljivanja prometa 1968. godine prvi predložio Bruynoughe [135].

MSA [136] predstavlja puno općenitiji i robusniji pristup od prethodno navedenog. Umjesto izračunavanja težinskih čimbenika u koraku traženja linije, MSA koristi unaprijed određene fiksne težinske čimbenike. Stoga je ovu metodu puno jednostavnije programirati, ali je često i znatno sporija.

5.3. Stohastička korisnička ravnoteža

Stohastičko dodjeljivanje prometa obično koristi multinomial logit (MNL) model za raspoređivanje putnika između mogućih putova. MNL model pretpostavlja istu distribuciju pogreške u pogledu korisnosti koja se zasniva na Gumbelovoj distribuciji. Ovaj se model može predstaviti sljedećim izrazom:

$$P(i) = \frac{e^{-\theta L_i}}{\sum_{j \in C_n} e^{-\theta L_j}}, \quad (8)$$

gdje su:

$P(i)$ – vjerojatnost korištenja puta i (pod pretpostavkom da su karakteristike putnika homogene, može se tumačiti i kao udio putovanja u paru ishodište-odredište koristeći put i)

C_n – skup izbora mogućih putova za svaki n

L_i, L_j – dužina puta i i j

θ – koeficijent korisnosti ili parametar brzine.

Za upotrebu programskog rješenja koje koristi MNL neophodno je prepoznati moguće putove i odrediti vrijednosti atributa tih putova poput udaljenosti, vremena putovanja i cestarina. U stvarnosti broj mogućih putova može biti izrazito velik, iako je putnicima privlačan i prihvatljiv samo njihov manji dio.

Godine 1971. razvijen je STOCH algoritam [137] za pridruživanje putova cestovnim dionicama u skladu s MNL funkcijom, ali bez eksplicitnog poznavanja mogućih putova u C_n . STOCH algoritam koristi skup izbora koji sadrži sve putove koji će putnika odvesti dalje od

ishodišta i bliže odredištu. U literaturi koja se bavi stohastičkim dodjeljivanjem prometa takvi se putovi smatraju razumnijima i učinkovitijima.

Da bi se postigla dosljednost između pretpostavljenih vremena putovanja prilikom stohastičkog dolaska u promatrani mrežni segment i vremena putovanja s uključenim zagušenjem prometnog toka, može se koristiti iterativni postupak kao i u slučaju s determinističkom korisničkom ravnotežom. Rezultirajuća dosljednost naziva se stohastička korisnička ravnoteža. U svrhu dobivanja brže konvergencije SUE algoritma od one dane MSA pristupom Fisk u svom radu [138] predstavlja minimalističku formulaciju, a Chen i Alfa [139] prilagođavaju algoritam konveksnih kombinacija. U svakoj se iteraciji pomoću STOCH algoritma putnici dodjeljuju cestovnim dionicama, a zatim se preračunava vrijeme zagušenja i usrednjuje s vrijednostima prethodne iteracije.

5.4. Metoda označavanja

Pristup označavanjem ili metoda označavanja jedna je od tehnika koja se može koristiti u svrhu određivanja mogućih putova u okviru putovanja ishodište-odredište uzimajući pritom u obzir različite funkcije ciljeva pri traženju rute. Dio će vozača tijekom putovanja željeti čim više umanjiti samo vrijeme putovanja, a dio može osjećati nelagodu pri izvođenju zahtjevnijih radnji u prometu i zato izbjegavati promjene prometnog traka, autoceste, visoko zagušene prometne dionice ili raskrižja bez signalne regulacije prometa. S druge strane, neki vozači mogu putovati sa svrhom koja nije strogo poslovnog i obvezujućeg karaktera i kada je vrijeme dolaska na odredište elastično te koristiti rute bogate okolnim informacijama ili povijesno-kulturnim znamenitostima. Svaki je od navedenih čimbenika u izboru rute i osnovni kriterij u izboru najprikladnije rute i stoga je svaku rutu moguće *označiti* prema danom kriteriju ili kriterijima za koje oni predstavljaju optimum. Ovaj su pristup predložili Ben-Akiva, Bergman, Daly and Ramaswamy [140] koristeći sljedeće oznake za pojedine kriterije: minimalno vrijeme, minimalna udaljenost, maksimalan doživljaj okoline, minimalna prometna signalizacija, minimalno prometno zagušenje, maksimalna uporaba prometnica visokog kapaciteta, maksimalno putovanje komercijalnim područjem, maksimalna kvaliteta prometnice i hijerarhijski uzorak putovanja razmatran do treće razine.

U ovom pristupu u skladu s iznesenim karakteristikama nameće se slučaj da dvije ili više oznaka ukazuju na istu rutu. U tom se slučaju koristi NL model (*nested logit*). NL model se najčešće koristi za izbor modova putovanja i pri višedimenzionalnim izborima (npr. mod putovanja i odredište). U slučaju izbora moda putovanja, koristi se kada je alternative moguće svrstati u grupe s općenitim atributima koji se dodatno ne razmatraju ili grupe čiji članovi imaju više zajedničkih obilježja nego članovi drugih grupa (npr. grupu "privatan

prijevoz" mogu činiti putnici u automobilu, vozači automobila i putnici u taksiju, dok grupu "javni prijevoz" mogu činiti putnici u autobusu, putnici u vlaku i putnici u tramvaju). U višedimenzionalnim izborima ishod prvog izbora određuje način svrstavanja u grupe što ih čini "ugniježđenim" od čega je i potekao naziv modela. Zbog grafičkih prikaza koji se mogu pronaći u literaturi i hijerarhijske strukture kojom se najčešće prikazuje grupiranje alternativa ovaj se model još naziva i *tree logit model*. Dijeljenje skupa izbora C_n u M gnijezda C_{mn} , može se izraziti kao

$$C_n = \bigcup_{m=1}^M C_{mn} \quad (9)$$

i

$$C_{mn} \cap C_{m',n} = \emptyset \forall m \neq m'. \quad (10)$$

Vjerojatnost izbora alternative je produkt izbora "gnijezda" i izbora alternative unutar "gnijezda"

$$P(i|C_n) = P(C_{mn}|C_n)P(i|C_{mn}). \quad (11)$$

Unutar "gnijezda" vjerojatnost odabira alternative temelji se na MNL modelu

$$P(i|C_{mn}) = \frac{e^{V_{in}}}{\sum_{j \in C_{mn}} e^{V_{jn}}}, \quad (12)$$

gdje je V_{in} sustavna korisnost alternative i za n putnika.

Korisnost "gnijezda" temelji se na kombinaciji korisnosti alternativa unutar "gnijezda", $I_{C_{mn}}$ i korisnosti od atributa "gnijezda" koji ne može biti pridružen jednoj alternativni niže razine, $\tilde{V}_{C_{mn}}$, odnosno

$$V_{C_{mn}} = \tilde{V}_{C_{mn}} + \mu I_{C_{mn}}. \quad (13)$$

Ben-Akiva i Lerman [141] pokazali su da očekivana maksimalna korisnost može biti izračunata logaritmom zbroja

$$I_{C_{mn}} = \ln \sum_{j \in C_{mn}} e^{V_{jn}}. \quad (14)$$

Ovaj izraz predstavlja korisnost svih alternativa u "gnijezdu" pa se stoga naziva *uključena vrijednost* ili *uključeni trošak*. Uključena se vrijednost izbora odredišta često koristi kao

mjera pristupačnosti. U teoriji diskretnih izbora predlaže se da koeficijent uključene vrijednosti (ugniježdjeni koeficijent) treba biti između 0 i 1. Kada je vrijednost tog koeficijenta 0 predlažu se dvije neovisne ili nevezane odluke, a za vrijednost 1 se NL model reducira na MNL model. Vrijednost koeficijenta veća od 1 ukazuje na potrebu korištenja druge "ugniježdjene" strukture okretanjem hijerarhijskog reda višedimenzionalnog izbora.

U metodi označavanja su označeni putovi organizirani u NL strukturu u kojoj fizički putovi oblikuju gornju razinu hijerarhije "gnijezda", a označeni putovi se grupiraju u skladu s fizičkim putovima. Ipak, putnici radije biraju fizičke putove nego oznake. Ovo ne predstavlja uobičajenu očekivanu strukturu NL modela gdje je poznat izbor alternativa niže razine. Procjena modela označavanja obuhvaća analitički izračun uključenih vrijednosti i izradu prilagođenog programa za procjenu maksimalne vjerodostojnosti koji će odrediti koeficijente nelinearnog parametarskog modela predloženog izrazima od 2 do 5. Identifikacija parametara modela i nekoliko odgovarajućih specifikacija predložene su u ranije spomenutom radu [140].

5.5. Algoritam K različitih putova

Algoritam K različitih putova zapravo predstavlja višestruko ponavljanje algoritma najkraćeg puta što rezultira kolekcijom putova. Kako dodatni putovi imaju impedanciju blisku impedanciji najkraćeg puta tako se očekuje da će ih putnik uzeti u obzir pri razmatranju. Jedna klasa algoritama koristi točno određeno rješenje za problem traženja K putova s minimalnim vrijednostima dane funkcije cilja (npr. najmanje udaljenosti, najmanje vrijeme zagušenja i sl.). Heuristička rješenja su također vrlo učestala i moguće ih je podijeliti u tri grupe:

1. Eliminacijske tehnike – uklanjaju prometnu dionicu najkraćeg puta u mreži kako bi prepoznali više kratkih putova
2. Metoda otežavajućih čimbenika – povećavaju impedanciju prometne dionice najkraćeg puta, ali je ne uklanjaju iz mreže prije potrage za kraćim putovima
3. Metoda grananja – odabire prometnu dionicu prethodno prepoznatog kratkog puta i stvara novi put tražeći najkraći put od ishodišta do početka odabrane prometne dionice i od kraja prometne dionice do odredišta.

Prva grupa rješenja predstavlja proširenje postojećih pristupa koji koriste postavljanje i korigiranje oznaka kako bi odredili najkraći put poput Dijkstra algoritma. Umjesto jedne oznake pridružene svakom prometnom čvoru koristi se polje od K oznaka kako bi se, pomoću

njih, putovi mogli sortirati rastućim redoslijedom u ovisnosti o dužini, vremenu putovanja ili drugom cilju.

Dio se autora ne slaže s upotrebljivošću ovih algoritama za odabir mogućih putova jer se svi putovi čine veoma sličnima, dok se drugi putovi koje bi vozač uzeo u razmatranje uopće ne prepoznaju.

U sljedećim trima cjelinama razmatrat će se primjena heurističkih pristupa za aproksimiranje problema K najkraćih putova koji se razlikuju u načinu prepoznavanja novih alternativnih putova.

5.6. Uklanjanje prometnih dionica

Uklanjanje prometnih dionica predstavlja pristup u kojem se iterativno pronalazi najkraći put, uklanjaju sve ili dio prometnih dionica iz mreže te zatim pronalazi novi najkraći put. Jedna od opasnosti uklanjanja svih ili većine prometnih dionica najkraćeg puta je da se tim postupkom ukloni i neophodni dio prometne mreže (glavno raskrižje putova) kako bi uopće postojao spoj između ishodišta i odredišta, a time i mogućnost pronalaska bilo kojih drugih putova od ishodišta do odredišta, pa tako i onih najkraćih. U stvarnosti redovito postoje alternativni pravci do glavnog raskrižja, ali se oni neće generirati ovom metodom. Kriterij za završavanje postupka iteracije je prekid prometne mreže.

Druga inačica ovog pristupa oslanja se na uklanjanje samo jedne prometne dionice u isto vrijeme što će rezultirati samo manjim odstupanjem od prethodno opisanog problema. Generiranje alternativnih putova moguće je uklanjanjem pojedinih prometnih dionica iz najkraćeg puta, zatim svih kombinacija parova prometnih dionica, itd. U praksi, put može sadržavati i do 300 prometnih dionica što ovaj postupak čini iznimno složenim i zahtjevnim. Nadalje, jedna prometna dionica ili kombinacija prometnih dionica mogu biti uklanjane i iz putova koji po dužini slijede najkraći mogući put respektivno.

5.7. Metoda otežavajućih čimbenika

Umjesto uklanjanja prometne dionice, metoda otežavajućih čimbenika¹⁶ povećava impedanciju prometnih dionica korištenih u prethodno pronađenom najkraćem putu prilikom traženja novoga puta. Prednost ovoga pristupa je u činjenici da se prometna mreža ne može prekinuti jer se sve prometne dionice čija je impedancija povećana mogu naknadno ponovo koristiti u nekoj od sljedećih iteracija. De la Barra, Perez i Anez [142] opisuju tehniku kojom nakon što je pronađen najkraći put svakoj se prometnoj dionici povećava vrijednost

¹⁶ Ovaj se pristup u literaturi može pronaći pod nazivom *link penalty* ili *overlap penalty*.

impedancije za fiksni postotak, poslije čega se ponavlja cjelokupni postupak. Park i Rilett [143] jednim dijelom mijenjaju prethodno navedeni pristup na način da ne povećavaju impedanciju prometnim dionicama koje se nalaze u nekom određenom radijusu od ishodišta i odredišta kako se ne bi stvarala nepotrebna devijacija na početku i na kraju puta. Za određivanje prometnih dionica u blizini ishodišta i odredišta kojima se neće povećati impedancija može se koristiti i vrijeme putovanja.

5.8. Metoda grananja

Heuristički pristup pod nazivom metoda grananja prvi su puta predložili Bellman i Kalaba [144]. Metoda grananja prvo koristi proceduru za pronalazak najkraćeg puta. Nakon toga odabire se jedna prometna dionica čiji jedan kraj počiva na najkraćem putu. Tu dionicu može odabrati nasumično ili prema nekom od atributa (npr. prometna dionica s najvećim kapacitetom). Novi se put generira na način da se na najkraći mogući način spoji ishodište s početkom prometne dionice i kraj prometne dionice s odredištem. Put dobiven na opisani način se zatim sprema i sortira. Dodatni putovi mogu se generirati korištenjem drugih prometnih dionica na isti način ili korištenjem najkraćeg prethodno generiranog puta i njemu pripadajućih prometnih dionica.

5.9. Simulacijski pristup

Algoritam *K* najkraćih putova može koristiti sve atribute za raspoložive prometne dionice koje sadrži. Tako se u više iteracija ovaj algoritam može koristiti za izračunavanje npr. najprije udaljenosti, zatim vremena slobodnog toka i konačno, očekivanog vremena kao funkcije cilja za prvi najkraći put. Ovi su atributi redovito u određenom međusobnom odnosu. Metoda *K* najkraćih putova generira putove koji su često veoma slični i ne obuhvaćaju cjelokupan opseg putova koje vozač može razmatrati. Prema mišljenju analitičara vozači vrijeme putovanja doživljavaju s pogreškom pa je razumno pristupati problemu na način da se provodi nasumični odabir iz distribucije koja predstavlja opažanje vozača.

Sheffi i Powell [145] opisuju upotrebu Monte Carlo tehnike za primjenu multinomial Probit modela u svrhu dodjeljivanja prometa, jer model koji koristi Gaussovu distribuciju nema konvencionalno analitičko rješenje za ovaj problem. Primijenjena tehnika uključuje unaprijed određen broj iteracija za koje se vrijeme putovanja prometnim dionicama uzima iz Probit distribucije. Prometno dodjeljivanje pod nazivom "sve ili ništa" koristi se za učitavanje prometnog volumena u prometnu mrežu. Na kraju se prometni tok iz svih iteracija usrednjuje da bi se dobio prometni tok koji se predviđa. Za potrebe generiranja, puno je

prihvatljivije nakon iteracije spremati sve prometne dionice najkraćeg puta, nego uprosječene prometne tokove.

Ova tehnika razvijena je kako bi se koristio Probit model tamo gdje su distribucijski parametri i parametri korisnosti već procijenjeni. Distribucijski parametri koji su uzeti u svrhu simulacije moraju biti iz nekog drugog izvora jer je namjera generirati putove za procjenu modela izbora rute. Oni mogu biti odabrani iz modela opaženih vremena putovanja, kalibrirani odabirom vrijednosti da se maksimizira pokrivenost ili na neki drugi način stvoreni putevi sa željenim karakteristikama.

5.10. C-Logit

Jedno od ograničenja Logit izraza je pretpostavka da su pogreške neovisne i jednako distribuirane Gumbelovom distribucijom (*Independent and identically distributed, i.i.d.*) što rezultira svojstvom binarne neovisnosti¹⁷. Ovo je svojstvo prikazano primjerima na slici 22. Putovi 1 i 2 dijele isti segment dužine (ili impedancije) $T-d$, ali se razlikuju u dijelu označenom s d . Pod pretpostavkom da se korisnost rute temelji samo na udaljenosti, koja je za sve tri rute jednaka, MNL modeli će predvidjeti da je udio svake rute jedna trećina. MNL model je dosljedan ljudskoj intuiciji kada je preklapanje putova 1 i 2 jako malo ($d \rightarrow T$), no kada se preklapanje približava dužini cijele rute ($d \rightarrow 0$) očekuje se da put 3 ima udio od jedne polovine, a putova 1 i 2 od jedne četvrtine (dakle jednu polovinu na dijeljenom segmentu) jer bi u suprotnom put 1 i 2 u dijeljenom segmentu imali previše dodijeljenog prometa (dvije trećine) i postojala bi potencijalna mogućnost nastanka zagušenja.


Cascetta, Nuzzolo, Russo i Vitetta [146] predlažu C-Logit model kako bi očuvali jednostavnost računanja logit forme, ali i proizveli puno intuitivnije predviđanje udjela ruta.

C-Logit model dodaje prilagodbu korisnosti rute koja se temelji na količini preklapanja s drugim rutama. Ova se prilagodba naziva čimbenikom istovjetnosti (*commonality factor, CF*) i prikazuje se na sljedeći način


$$P(i|C_n) = \frac{e^{V_{in} + CF_{in}}}{\sum_{j \in C_n} e^{V_{jn} + CF_{jn}}} \quad (15)$$

¹⁷ Binarna neovisnost se u literaturi još naziva i *independence of irrelevant alternatives* (IIA).

Primjer 1.



Primjer 2.



Slika 22. Primjeri rutiranja

Vrijednost CF treba uvijek biti negativna jer će preklapljeni putovi imati manji udio od jedinstvenih ruta. CF je često logaritamskog oblika kako bi u slučajevima jedinstvene rute logaritamska transformacija imala argument jednak jedinici i ne bi djelovala na korisnost puta. Za putove s preklapanjem taj je argument manji od jedinice i vjerojatno se približava nuli, pa je stoga korisnost takvih putova i manje privlačna pri razmatranju.

Prethodno navedeni autori predlažu četiri različita oblika za CF kako slijedi:

$$CF_{in} = -\beta_0 \ln \sum_{j \in C_n} \left(\frac{L_{ij}}{\sqrt{L_i L_j}} \right)^{\gamma_k}, \quad (16)$$

$$CF_{in} = -\beta_0 \ln \sum_{a \in \Gamma_i} \frac{I_a}{L_i} N_{an}, \quad (17)$$

$$CF_{in} = -\beta_0 \ln \sum_{a \in \Gamma_i} \frac{I_a}{L_i} \ln N_{an}, \quad (18)$$

$$CF_{in} = -\beta_0 \ln \left[1 + \sum_{\substack{j \in C_n \\ j \neq i}} \left(\frac{L_{ij}}{\sqrt{L_i L_j}} \right) \left(\frac{L_i - L_{ij}}{L_j - L_{ij}} \right) \right], \quad (19)$$

gdje su:

β_0 i γ_k – koeficijenti koji se predviđaju ili kalibriraju

L_{ij} – udaljenost putova i i j

Γ_i – skup dionica puta i

l_a – dužina prometne dionice a

N_{an} – $\sum_{j \in C_n} \delta_{aj}$ za stvarne prometne dionice (1 za spojeve centroida¹⁸)

δ_{aj} – "dummy" varijabla, 1 ako put j koristi prometnu dionicu a ili 0 u svakom drugom slučaju.

Promatrajući neke teoretske mreže i uspoređujući predviđanja Probit i C-Logit modela autori zaključuju da izraz 6 najviše nalikuje na probit udio, iako se vrijednost γ mora kalibrirati. Također, uviđaju da izraz 7 daje iste rezultate kao izraz 6 kada je korisnost putova jednaka. Nedostatak C-Logit metode je manjak teorije koja bi odredila koji oblik čimbenika istovjetnosti treba koristiti.

5.11. Logit veličine puta

Logit veličine puta (*Path-Size Logit*, PSL) predstavlja primjenu teorije diskretnog izbora na sveukupne alternative koje su se koristile u drugim prometnim slučajevima poput izbora odredišta. Njime se teorija ponašanja pokušava uključiti u C-Logit proces prilagođavanja. Stoga se i u ovom slučaju, kao i u prethodnom, dodaje prilagodba korisnosti alternativnih ruta:

$$P(i|C_n) = \frac{e^{V_{in} + \ln PS_{in}}}{\sum_{j \in C_n} e^{V_{jn} + \ln PS_{jn}}} = \frac{PS_{in} e^{V_{in}}}{\sum_{j \in C_n} PS_{jn} e^{V_{jn}}}, \quad (20)$$

gdje je PS_{in} veličina puta i za osobu n .

¹⁸ Centroid je točka koja predstavlja centar aktivnosti u zoni i spaja tu zonu s prometnom mrežom. Zone su mala geografska područja koja čine promatranu cjelinu. Spojevi centroida predstavljaju prosječan trošak (vrijeme, udaljenost) priključivanja na prometnu mrežu za putove čija su ishodišta u odnosnoj zoni.

Put bez preklapanja cestovnih dionica ne treba prilagodbu korisnosti i ima veličinu jedan. Kada se jedinstveni put podijeli na više putova čija je veličina ista, može se zamisliti da je veličina djelomično preklopljenih putova sastavljena od veličina prometnih dionica koje su zatim otežane nekom odgovarajućom mjerom (npr. impedancijom odnosno udjelom kojim prometna dionica doprinosi ukupnoj dužini puta). U svakom se slučaju treba posvetiti pažnja kada se prometna dionica podijeli između putova različitih dužina.

Logit veličine puta uveli su Ben-Akiva i Ramming [147] predstavljajući ga sljedećim izrazom

$$PS_{in} = \sum_{a \in \Gamma_i} \left(\frac{l_a}{L_i} \right) \frac{1}{N_{an}} = \sum_{a \in \Gamma_i} \left(\frac{l_a}{L_i} \right) \frac{1}{\sum_{j \in C_n} \delta_{aj}}. \quad (21)$$

Impedancija dijela puta uvjetovana određenom dionicom predstavljena je s l_a/L_i , dok se ostatak izraza, $1/N_{an}$, odnosi na broj putova koji koriste cestovnu dionicu.

Na drugi dio izraza ne utječe dužina ili impedancija putova za prometne dionice koje ne koristi samo jedan put već više njih. Stoga ovaj izraz ne pruža zadovoljavajuću preciznost kada su proizvoljno dugi putovi uključeni u skup izbora. Na primjer, kada bi u primjeru 1 na prethodnoj slici desnu prometnu dionicu prvog puta učinili jako dugačkom, desni dio izraza ostao bi jednak jednoj polovini i za put 1 i za put 2. Put 2 ima veličinu manju od jedan. Veličina puta 1 bila bi vrlo blizu jedan jer je njegova većina sadržana u drugoj prometnoj dionici. Put 3 se razlikuje i njegova je veličina 1. Pri razmatranju vjerojatnosti izbora, put 1 bi imao veoma mali udio zbog svoje velike dužine. Putovi 2 i 3 imaju istu dužinu, ali put 2 ima nešto manju veličinu nego put 3. Stoga bi model predvidio da put 2 ima manji udio nego put 3. Iako put 1 ne bi uopće ušao u izbor, vjerojatnost ne bi bila jedna polovina, pa bi put 3 bio bezrazložno više opterećen prometom.

5.12. Poprečno "ugniježđeni" Logit

Poprečno "ugniježđeni" Logit model (*Cross-Nested Logit*, CNL) je svoju primjenu u izboru rute prvi puta doživio uporabom Logit modela s "ugniježđenim" prometnim dionicama [148]. Poprečno ugniježđeni Logit model, Multinomial Logit model (s varijacijama C-Logit i PS Logit) i ugniježđeni Logit model (uključujući primjenu u pristupu označavanjem) dio su modela generaliziranih ekstremnih vrijednosti (*Generalized Extreme Value*, GEV).

CNL model se razlikuje od NL modela po tome što dozvoljava da alternative niže razine mogu pripadati u više od jednog "gniježda". Stoga se određuje skupina parametara za svaku alternativu i i svako "gniježdo" m , α_{mi} ($0 \leq \alpha_{mi} \leq 1$), koja predstavlja stupanj "članstva" ili uključenu težinu alternative i u "gniježdu" m . Zbroj parametara α_{mi} svih "gniježda" je

generalno normalizirana na jedan za svaku alternativu niže razine i . Vjerojatnost izbora u poprečno "ugniježđenom" Logit modelu je

$$P(i|C_n) = \sum_{m=1}^M P(C_{mn}|C_n) P_n(i|C_{mn}), \quad (22)$$

$$P(i|C_{mn}) = \frac{\alpha_{mi} e^{V_{in}}}{\sum_{j \in C_{mn}} \alpha_{mj} e^{V_{jn}}}, \quad (23)$$

$$P(C_{mn}|C_n) = \frac{e^{V_{C_{mn}} + \mu_m I_{C_{mn}}}}{\sum_{l=1}^M e^{V_{C_{ln}} + \mu_m I_{C_{ln}}}}. \quad (24)$$

Za poprečno "ugniježđeni" Logit model vrijedi da je

$$I_{C_{mn}} = \ln \sum_{j \in C_{mn}} \left(\alpha_{mj} e^{V_{jn}} \right)^{1/\mu_m}, \quad (25)$$

što uvršteno u početni izraz daje

$$P_n(i|C_n) = \frac{\sum_{m=1}^M \left(\alpha_{mi} e^{V_{in}} \right)^{\frac{1}{\mu_m}} \left(\sum_{j \in C_{mn}} \left(\alpha_{mj} e^{V_{jn}} \right)^{\frac{1}{\mu_m}} \right)^{\mu_m - 1}}{\sum_{m=1}^M \left(\sum_{j \in C_{mn}} \left(\alpha_{mj} e^{V_{jn}} \right)^{\frac{1}{\mu_m}} \right)^{\mu_m}}. \quad (26)$$

CNL model se može postepeno reducirati na MNL model ako su svi parametri μ_m jednaki jedan:

$$P_n(i|C_n) = \frac{\sum_{m=1}^M \left(\alpha_{mi} e^{V_{in}} \right) \left(\sum_{j \in C_{mn}} \left(\alpha_{mj} e^{V_{jn}} \right) \right)^{\mu_m - 1}}{\sum_{m=1}^M \left(\sum_{j \in C_{mn}} \left(\alpha_{mj} e^{V_{jn}} \right) \right)} = \frac{\sum_{m=1}^M \left(\alpha_{mi} e^{V_{in}} \right)}{\sum_{j \in C_{mn}} \sum_{m=1}^M \left(\alpha_{mj} e^{V_{jn}} \right)} = \frac{e^{V_{in}} \left(\sum_{m=1}^M \alpha_{mi} \right)}{\sum_{j \in C_{mn}} e^{V_{jn}} \sum_{m=1}^M \left(\alpha_{mj} \right)} \quad (27)$$

i s obzirom da je zbroj svih α jednak jedinici ili jednakoj konstanti za sve alternative j , izraz se reducira na MNL model vjerojatnosti.

U LN Logit modelu prometne dionice (označene s a) oblikuju strukturu gnijezda dok rute (označene s i) oblikuju alternative niže razine. Za uključenu težinu vrijedi

$$\alpha_{ai} = \frac{l_a}{L_i} \delta_{ai} \quad (28)$$

gdje su:

l_a – dužina prometne dionice a (ili vrijeme putovanja njome)

L_i – dužina rute i (ili vrijeme putovanja njome)

δ_{ai} – "dummy" varijabla koja iznosi 1 kada ruta i prolazi prometnom dionicom a ili 0 u svim drugim slučajevima.

Provedena istraživanja najčešće su obuhvaćala manje teoretske mreže ili stvarne mreže s velikim ograničenjima jer je ova metoda, za prometnu mrežu sa stvarnim brojem prometnih dionica po svakom putu, vrlo složena i računalno veoma zahtjevnja. Koeficijent μ (parametar skaliranja) može biti procijenjen ako postoji dovoljno podataka za njegovo prepoznavanje, stoga se u većini slučajeva koristila konstantna vrijednost.

5.13. Probit i Logit jezgra

Prikladnost uporabe Probit modela za izbor rute počela se istraživati nakon spoznaje da IIA svojstvo Logit modela teško može prikazati učinak preklapajućih putova. Probit model se temelji na pretpostavci da pogreška ima viševerijantnu normalnu distribuciju što je suprotno od distribucije ekstremnih vrijednosti tipa I, koji se podrazumijeva za MNL, i drugih GEV modela.

Jedan od primjera primjene Probit modela izbora rute dali su Yai, Iwakura i Morichi [149]. Autori su pretpostavili da je kovarijanca korisnosti rute proporcionalna dužini preklapanja, te da pogreška ima promjenjivu varijancu koja je proporcionalna dužini rute ili impedanciji. Složenost upotrebe Probit modela očituje se u činjenici da ne postoji zatvoreni oblik za Gaussovu kumulativnu distribucijsku funkciju (*cumulative distribution function*, CDF) pa se moraju koristiti numeričke tehnike. Numeričke tehnike integriranja računalno su izvodeve kada je broj Gaussovih varijabli mali.

Daljnja istraživanja rezultirala su nizom alternativnih pristupa i rješenja od kojih se može izdvojiti Multinomial Probit s Logit jezgrom ili jednostavnije Logit jezgra (Logit Kernel), a koju dio autora u literaturi naziva i hibridni Logit. Ovaj se model u općem obliku može prikazati kao vektorski zapis

$$\mathbf{U} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\varepsilon} = \mathbf{X}\boldsymbol{\beta} + \mathbf{F}\mathbf{T}\boldsymbol{\zeta} + \mathbf{v}, \quad (29)$$

gdje su:

- \mathbf{U} – vektor redak J_n korisnosti
- $\boldsymbol{\beta}$ – vektor stupac K nepoznatih parametara
- \mathbf{X} – matrica nezavisnih varijabli J_n puta K
- $\boldsymbol{\zeta}$ – vektor stupac M i.i.d. standardnih normalnih varijabli koje predstavljaju nepromatrane čimbenike
- \mathbf{F} – matrica težinskih koeficijenata J_n puta M
- \mathbf{T} – donje trokutasta matrica M puta M nepoznatih parametara (moraju se zasebno odrediti)
- \mathbf{v} – vektor redak J_n i.i.d. Gumbelovih varijabli s parametrom skaliranja μ .

Prema tome je

$$\text{Var}(\boldsymbol{\varepsilon}) = \mathbf{F}\mathbf{T}\mathbf{T}^T\mathbf{F}^T + (g / \mu^2) \mathbf{I}_{J_n}, \quad (30)$$

gdje je g varijanca standardne Gumbelove varijable $\pi^2 / 6$.

Elementi matrice \mathbf{F} i \mathbf{T} mogu biti procijenjeni ili određeni iz podataka. Prednost Logit jezgre pred čistim Probit modelom je upravo navedeno svojstvo, tako da ako su korelacije unakrsnih alternativa procijenjene nulom, model se svodi na MNL. Različito određene \mathbf{F} i \mathbf{T} koriste se u različite svrhe.

Na primjer, uvođenjem slučajnog koeficijenta k -te nezavisne varijable koristit će se $\mathbf{F} = \mathbf{X}_k$ i $\mathbf{T} = \boldsymbol{\gamma}_k$ gdje je $\boldsymbol{\gamma}_k$ parametar koji se odnosi na širenje β_k .

Model Logit jezgre poput Multinomial Probit modela ima problem izračunavanja složenijih mrežnih struktura.

5.14. Implicitna raspoloživost / perceptivni Logit

Cascetta, Papola, Russo i Vitetta [150] uvode implicitnu raspoloživost / perceptivni Logit model (*Implicit Availability/Perception Logit*, IAP Logit) kao prikladan način za ugradnju svjesnosti puta u modeliranje izbora rute bez zahtjeva za generiranjem skupa eksplicitnih izbora. Iako IAP Logit koristi logaritamsku korekciju poput C-Logita, motivacija za korištenje korekcije je različita. C-Logit koristi korekciju kako bi prilagodio udio puta MNL

predviđanja koji će put imati ako je različit od ostalih. IAP Logit koristi korekciju kako bi smanjio udio puta odražavajući time vjerojatnost da putnik nije svjestan puta ili put ne može koristiti. Vjerojatnost $P_n(i)$ da putnik n odabere rutu i u IAP Logit modelu je

$$P_n(i) = \frac{e^{V_i + \ln \mu_n(i)}}{\sum_{j \in M} e^{V_j + \ln \mu_n(j)}}, \quad (31)$$

gdje M predstavlja glavni skup izbora, odnosno skup svih mogućih ruta. Vrijednost parametra $\mu_n(i) = 1$ označava da je put i raspoloživ, dok $\mu_n(i) = 0$ označava da put nije raspoloživ ili ga putnik nije svjestan. Kada je $\lim_{\mu_n \rightarrow 0} \ln \mu_n = -\infty$ i eksponent korisnosti za neraspoloživu alternativu je nula. IAP Logit model može se zapisati i kao

$$P_n(i) = \frac{\mu_n(i) e^{V_i}}{\sum_{j \in M} \mu_n(j) e^{V_j}}. \quad (32)$$

Kako analitičari ne mogu sa sigurnošću odrediti $\mu_n(i)$ tada se on tretira kao slučajna varijabla s očekivanjem $\bar{\mu}_n(i)$. U tom se slučaju $\mu_n(i)$ može zamijeniti s očekivanom vrijednošću iz izraza (31). Bolja približna vrijednost dobiva se razvojem Taylorovog reda drugog stupnja i uz pretpostavku da $\mu_n(i)$ ima maksimalnu varijancu što je rezultat Bernoullijeve distribucije. Rezultirajući model ima oblik

$$P_n(i) = \frac{\exp \left[V_i + \ln \bar{\mu}_n(i) - \frac{1 - \bar{\mu}_n(i)}{2 \bar{\mu}_n(i)} \right]}{\sum_{j \in M} \exp \left[V_j + \ln \bar{\mu}_n(j) - \frac{1 - \bar{\mu}_n(j)}{2 \bar{\mu}_n(j)} \right]}. \quad (33)$$

Za $\bar{\mu}_n(i)$ se pretpostavlja binarni Logit

$$\bar{\mu}_n(i) = \frac{1}{1 + \exp \left(\sum_{k=1}^K \gamma_{bk} Y_{ink} \right)}, \quad (34)$$

gdje je Y_{ink} k -ta varijabla u odnosu na raspoloživost ili svjesnost (percepciju) alternative i za osobu n , a γ_{bk} koeficijent koji treba procijeniti.

5.15. Generiranje skupa izbora i izbor rute

Implicitni pristup IAP Logita koji upućuje na alternative koje putnici razmatraju unutar njihovog skupa izbora može biti u suprotnosti s eksplicitnim generiranjem skupa izbora (*choice set generation*, CSG). Takav pristup uključuje dvije faze u kojima se najprije odrede alternative koje će korisnik razmatrati, a zatim se u drugoj fazi unutar tih alternativa određuje odabrana alternativa. U drugoj se fazi obično koriste modeli slučajnih korisnosti.

Uporabom determinističkih ili stohastičkih pravila može se provesti generiranje nekompensacijskog skupa izbora. Primjer determinističkog pravila je eliminacija po aspektu (*Elimination by Aspects*, EBA) [151]. Prema tome pravilu bilo koja alternativa koja ima vrijednost atributa pored nekog praga (npr. vrijeme putovanja duže od dva sata) izbacuje se iz skupa izbora. Također, određene socioekonomske karakteristike mogu eliminirati dio mogućih alternativa (npr. nepoložen vozački ispit ili nedovoljan osobni dohodak isključuje samostalnu vožnju). Deterministička pravila skupa izbora često se oslanjaju na heuristička pravila i procjene. Pragovi koji se koriste u primjeni ovih pravila kalibriraju se promatranjem i minimiziranjem broja eliminiranih odabranih alternativa.

Za određivanje alternativa koje će vjerojatno biti u skupu izbora putnika mogu se koristiti i stohastička pravila. Ova tehnika zahtijeva cijeli skup mogućih alternativa, odnosno glavni skup izbora M i često se naziva probablističko ili latentno generiranje skupa izbora. Osnovni izraz za vjerojatnost neke alternative i je

$$P_n(i) = \sum_{C \in G} P_n(i|C) P_n(C), \quad (35)$$

gdje je G skup svih mogućih skupova izbora, odnosno skup svih nepraznih podskupova od M . G će se sastojati od $2^J - 1$ elemenata skupa izbora (J je broj alternativa u glavnom skupu izbora M) ako se raspoloživost neke alternative ne može izvesti iz raspoloživosti ostalih alternativa. To znači da svaka alternativa može ili ne mora biti raspoloživa (2^J mogućnosti), ali budući da izbor mora biti moguć, barem jedna od alternativa mora uvijek biti raspoloživa što znači da skup izbora G ne može biti prazan.

Izraz (11) može se promatrati i kroz primjenu tzv. lančanog pravila vjerojatnosti (*Chain Rule of Probability*). U tu svrhu može se stvoriti vrlo velika kontingencijska tablica u kojoj će sve alternative biti prikazane u redovima, a skupovi izbora u stupcima. Pojedina polja navedene tablice bila bi popunjena nulama jer alternative nisu članovi odgovarajućeg skupa izbora. Produkt unutar zbroja, $P_n(i|C) P_n(C)$ je zajednička vjerojatnost da će osoba uzeti u obzir skup izbora C i odabrati alternativu i . Granična je vjerojatnost od interesa ako je odabrana alternativa i .

Vrlo je teško direktno promatrati skup izbora pojedinca. Čak ni najbolja oprema ne može prepoznati neodabrane alternative. Moguće je u tu svrhu koristiti metodu ankete, ali je teško razlikovati alternative koje su neraspoložive od onih koje putnik zbog neprivlačnosti doživljava kao neraspoložive. Stoga većina pristupa generiranju skupa izbora tretira skup izbora pojedinca kao latentnu klasu. Na raspoloživost alternativa mogu utjecati i druge latentne varijable (npr. korisnost alternative).

Nakon prethodno opisanih značajki modela izbora, $P_n(i|C)$, potrebno je isto učiniti i za model generiranja skupa izbora, $P_n(C)$. Tehnike za modeliranje skupa izbora mogu uključivati vezanost, slučajna ograničenja i neovisnu raspoloživost.

Model vezanosti podrazumijeva pojednostavljenje skupa G tako da su putniku raspoložive ili sve alternative ili je vezan samo uz jednu odabranu alternativu, odnosno

$$G = \left\{ \{1\}, \{2\}, \dots, \{i\}, \dots, \{J\}, \{1, 2, \dots, i, \dots, J\} \right\}, \quad (36)$$

Vjerojatnost vezivanja putnika uz jednu alternativu može biti određena kao fiksni dio ili kao funkcija socioekonomskih karakteristika (npr. osobni dohodak). Pretpostavka vezanja za alternativu značajno pojednostavljuje izraz (35) jer su samo dva člana zbroja različita od nule. Ipak, jednostavnost izračunavanja proizašla je na temelju postavljenih ograničenja pri tumačenju modela. Na primjer, putnik niti je vezan za jednu rutu niti poznaje sve moguće rute u mreži i razmatra od tri do pet alternativnih ruta.

Tehnika slučajnih ograničenja može biti upotrijebljena za određivanje čimbenika koji će voditi prema razmatranju određene alternative. Slučajno ograničenje se općenito može izraziti kao

$$A_{in}^* = 1 \Leftrightarrow h_{ink} \geq v_{ink} \quad \forall k \in K_i, \quad (37)$$

gdje su:

- A_{in}^* – latentna raspoloživost alternative i (jednaka jedinici ako je alternativa i raspoloživa ili je razmatra pojedinac n)
- h_{ink} – kriterijska funkcija koja se odnosi na alternativu i i može biti funkcija koeficijentata, socioekonomskih karakteristika i atributa alternative
- v_{ink} – slučajni prag sa središtem u nuli
- K_i – skup ograničenja koji se odnosi na alternativu i .

Vjerojatnost da je skup izbora C upravo skup koji putnik razmatra je

$$P_n(C) = \frac{P_n\left(\left[A_{in}^* = 1 \forall i \in C\right] \mid \left[A_{jn}^* = 0 \forall j \in M \setminus C\right]\right)}{1 - P_n\left(A_{ln}^* = 0 \forall l \in M\right)} \quad (38)$$

ili

$$P_n(C) = \frac{P_n\left(\left[h_{ink} \geq v_{ink} \forall k \in K_i, \forall i \in C\right] \mid \left[h_{jnk} < v_{jnk} \text{ za najmanje jedan } k \in K_j, \forall j \in M \setminus C\right]\right)}{1 - P_n\left(h_{lnk} < v_{lnk} \text{ za najmanje jedan } k \in K_l, \forall l \in M\right)}, \quad (39)$$

gdje je $M \setminus C$ komplement $M \cap C$ u M . Skup izbora ne može biti prazan pa je potrebna normalizacija nazivnika. Oblik $P_n(C)$ ovisi o pretpostavljenoj distribuciji za v_{nk} .

U modelu neovisne raspoloživosti pretpostavlja se da su raspoloživosti alternativa, A_{in}^* , neovisne jedna o drugoj ili da su kod slučajnih ograničenja v_{nk} neovisni. Time se omogućava zapis modela skupa izbora uporabom multiplikativnog svojstva neovisnih vjerojatnosti

$$P_n(C) = \frac{\prod_{i \in C} P_n(A_{in}^* = 1) \prod_{j \in M \setminus C} P_n(A_{jn}^* = 0)}{1 - \prod_{l \in M} P_n(A_{ln}^* = 0)} \quad (40)$$

i

$$P_n(C) = \frac{\prod_{i \in C} P_n(h_{ink} \geq v_{ink} \forall k \in K_i) \prod_{j \in M \setminus C} P_n(h_{jnk} < v_{jnk} \text{ za najmanje jedan } k \in K_j)}{1 - \prod_{l \in M} P_n(h_{lnk} < v_{lnk} \text{ za najmanje jedan } k \in K_l)}. \quad (41)$$

Ben-Akiva i Boccarà [152] pokazuju da latentni model generiranja skupa izbora bolje pristaje nego jednostavni MNL model. Uporabom indikatora skupa izbora može se postići i veća statistička učinkovitost, ali ista zahtijeva puno složeniji model.

6. NAPREDNI MODEL UPUĆIVANJA VOZILA NA RASPOLOŽIVA PARKIRALIŠNA MJESTA

Analiza cestovnog prometa i prometnih sustava predstavlja složen proces. Razlog tome najvećim dijelom leži u činjenici uključenosti velikog broja vozila u promet, koja su u međusobnoj interakciji i s vozačima jedinstvenih karakteristika čije je reakcije teško predviđati. Stoga se u navedenu svrhu koriste metode modeliranja i simulacije kako bi se opisale zakonitosti kretanja u prometu i pronašla odgovarajuća rješenja. Analiza se može provoditi na mezoskopskoj, makroskopskoj i mikroskopskoj razini, a u svrhu ovoga istraživanja koristit će se mikroskopska razlučivost.

Simulatori prometa su neophodan alat za proučavanje i istraživanje prometa. Mikrosimulacijska programska rješenja sposobna su modelirati kretanje pojedinih vozila koji putuju unaprijed određenom cestovnom mrežom. Matematički modeli su u osnovi njihov sastavni dio i osiguravaju realističan prikaz ponašanja vozača u prometnoj mreži. Za razliku od determinističkih modela, stohastički pristup i bolja rezolucija mikroskopskih simulacijskih programskih rješenja osiguravaju bolji prikaz ponašanja vozača i vozila u prometnoj mreži pogotovo kada se radi o složenim prometnim problemima poput utjecaja incidenata ili parkiranja na promet u cijelosti.

6.1. Struktura sustava cestovnog prometa

Modeli sustava cestovnog prometa u osnovi se sastoje od transportiranih entiteta, cestovnih vozila i cestovne mreže. Svaki od navedenih čimbenika odlikuju specifične karakteristike koje je potrebno odrediti u sklopu simulacijskog modela kako bi se u čim većoj mjeri ostvarila realističnost uvjeta u kojima predloženi napredni sustav treba djelovati. Za potrebe istraživanja i stvaranja mogućnosti za kvantitativno i kvalitativno ocjenjivanje naprednog modela upućivanja vozila na raspoloživa parkirališna mjesta, neophodno je odrediti odgovarajuća obilježja prometne infrastrukture, prometnih entiteta, vozača kao sudionika u prometu i ostalih čimbenika prometa koji će biti opisani u nekoliko sljedećih potpoglavlja.

6.1.1. Modeliranje prometne infrastrukture

U svrhu analiziranja utjecaja sustava s upućivanjem vozila na raspoloživa parkirališna mjesta autor je odabrao programsko rješenje za mikroskopsku simulaciju prometnih tokova pod nazivom VISSIM. Ovaj je višenamjenski prometni simulator njemačkog poduzeća PTV, zbog svojih mogućnosti analiziranja i optimiziranja prometnih tokova, odabran između

cijelog niza drugih različitih rješenja kao što su S-Paramics, AIMSUN, TransModeler, Cube Dynasim i sličnih. Rad VISSIM-a zasniva se na programskom jeziku C++ i objektno orijentiranom programiranju što ga, uz raspoloživo aplikacijsko programsko sučelje, čini prikladnim za uporabu vlastitih kontrolnih i drugih algoritama.

Prometna će se infrastruktura, odnosno cestovna mreža modelirati ovisno o namjeni uz manju ili veću sličnost sa stanjem u stvarnosti. U svrhu modeliranja prometne infrastrukture s višim stupnjem realističnosti VISSIM omogućava uporabu mapa s interneta, poput OpenStreetView ili Bing mapa, ili uvoz određenih rasterskih ili vektorskih formata koji su rezultat obrade u CAD ili GIS programima, odnosno nastali na osnovi skica i crteža samog korisnika. Cestovna se mreža obično prikazuje pomoću poveznica (*links*) koje se postavljaju na mjestima cestovnih dionica i osiguravaju prostor za promet vozila u jednom smjeru u jednoj ili više prometnih traka. Poveznice se međusobno spajaju priključcima (*connectors*) koji osiguravaju funkcionalnost prometnih tokova, odnosno promet vozila iz jedne poveznice u drugu. Priključcima se modeliraju i sva križanja poveznica te razdvajanje jedne poveznice u više njih. Potrebno je obratiti posebnu pažnju na potencijalno preklapanje poveznica i priključaka jer bi to moglo rezultirati nerealnim kapacitetom prometnice. Poveznice i priključci prema potrebi mogu imati i dodatna obilježja kojima se opisuju poput naziva, broja prometnih traka, širine, karakteristika ponašanja vozača itd.

Mjesta na kojima priključci spajaju poveznice koje se križaju mogu predstavljati signalizirana ili nesignalizirana raskrižja. Za signalizirana raskrižja potrebno je prvo odrediti signalne planove, odnosno režime rada pojedinih signalnih uređaja. Kod nesignaliziranih raskrižja poželjno je odrediti i pravila prioriteta ili konfliktna područja kako bi se osigurao čim realističniji promet vozila. Također, mogu se po potrebi postaviti znakovi za zaustavljanje i ograničenje brzine kretanja vozila te odrediti područja sa smanjenom brzinom vožnje, odnosno mjesta gdje je poželjno usporavanje nadolazećih vozila poput raskrižja i oštih zavoja.

Neovisno o tome je li prometna mreža modelirana na osnovi postojeće mape ili zamisli autora, ona može sadržavati i neke druge elemente uz prethodno navedene poveznice i priključke. Objekti koji još mogu činiti dio cestovne infrastrukture u osnovi se mogu podijeliti na točkaste i prostorne. Točkasti objekti nemaju fizičku dužinu i precizno su svojom pozicijom vezani uz određeni prometni trak (prometni znakovi za zaustavljanje ili ograničenje brzine kretanja, semafori i sl.), dok prostorni objekti obuhvaćaju određeni prostor pojedinog kolničkog traka (detektori prisutnosti i brzine vozila, stajališta javnog prijevoza putnika, područja ograničene brzine, parkirališna mjesta i sl.).

U svrhu istraživanja za potrebe ovoga rada izrađen je apstraktni simulacijski model gradskog središta koji je sastavljen od mreže prometnica s pripadajućim signaliziranim i

nesignaliziranim raskrižjima kako bi se prikazala učinkovitost sustava za upućivanje na raspoloživa parkirališna mjesta u odnosu na uobičajeno kruženje u potrazi za slobodnim parkirališnim mjestom.

6.1.2. Modeliranje cestovnog prometa

Promet vozila cestovnom mrežom može se modelirati statičkim rutama uz unaprijed određena mjesta učitavanja vozila u simulacijski model ili dinamičkim dodjeljivanjem prometa i dinamičkim rutama. Da bi se odredila kompozicija vozila na mjestima ulaska vozila u modeliranu prometnu mrežu, odnosno ulazni prometni volumen modelirane prometne mreže, potrebno je prvo odrediti tipove, klase i kategorije prometnih entiteta. Na slici 23. prikazani su tipovi prometnih entiteta koji se koriste u sklopu ovoga rada (u ovome slučaju samo vozila). Uz obična vozila, autobuse i teška teretna vozila koja se prije svega koriste za generiranje uobičajenog prometnog toka i tranzitni promet, koriste se i tipovi vozila RG 01 i RG 02 koji predstavljaju prometne entitete s ugrađenim sustavom za upućivanje na raspoloživa parkirališna mjesta. Za tipove vozila RG 01 i RG 02 određen je interval upućivanja od 60 sekundi i vremenski pomak pristizanja informacija od 8 sekundi.

Count: 5	No	Name	Category	Model2D3DDistr	ColorDistr1	OccupDistr	Capacity
► 1	100	Car	Car	10: Car	1: Default	1: Single Occupancy	0
2	200	HGV	HGV	20: HGV	1: Default		0
3	300	Bus	Bus	30: Bus	1: Default	1: Single Occupancy	999
4	610	RG 01	Car	10: Car	1: Default	1: Single Occupancy	0
5	620	RG 02	Car	10: Car	1: Default	1: Single Occupancy	0

Slika 23. Tipovi vozila u simulacijskom modelu

Više različitih tipova vozila koji imaju slične karakteristike mogu sačinjavati klasu vozila kako bi se naknadno u evaluaciji jednostavnije mogli razmatrati njihovi učinci. U simulacijskom se modelu nije u obzir uzimao pješački promet te promet svih potencijalno mogućih prometnih entiteta, jer su za navedeno istraživanje nebitni, već su se samo odredile različite kompozicije vozila kako bi se odvojio osnovni prometni tok od vozila koje traže raspoloživo parkirališno mjesto. Kompoziciju vozila osnovnog prometnog toka čine osobna vozila (98 % udjela) i teretna vozila (2 % udjela).

Nakon što je u simulacijskom modelu određena najmanje jedna kompozicija vozila može se odrediti i vremenski promjenjiv prometni volumen kojim ta vozila dopijevaju u prometnu mrežu za svaku pojedinačnu pristupnu prometnu dionicu. Prometni se volumen za pojedinu prometnu dionicu i odnosnu kompoziciju vozila opisuje količinom vozila koja u istu ulaze u razdoblju od jednog sata premda vremenski interval simulacije može biti veći ili manji od

navedenog vremena. Unutar danog vremenskog intervala vozila ulaze u skladu s Poissonovom distribucijom.

Za potrebe istraživanja provedenih u sklopu ovoga rada nisu se koristile statičke rute i jednostavan oblik dodjeljivanja prometa i određivanja ulaznog toka već dinamičko dodjeljivanje prometa gdje su podaci o prometnom toku sadržani u ishodište-odredište (*origin-destination*, OD) matricama koje su detaljnije opisane u potpoglavlju 6.5.

6.1.3. Ponašanje vozača

Model prometnog toka predstavlja osnovu za kretanje vozila u simulacijskoj prometnoj mreži. Dok većina programskih rješenja za mikroskopske simulacije prometa obično koristi determinističku logiku slijeđenja vozila i konstantne brzine u simulacijskoj prometnoj mreži, VISSIM prometni tok modelira stohastički promatrajući svaku kombinaciju čovjeka i odnosnog vozila kao jednu nerazdvojivu cjelinu. Za ovakav psihofizički model slijeđenja vozila i algoritme koji se zasnivaju na pravilima ponašanja vozača zaslužan je Rainer Wiedemann sa Sveučilišta u Karlsruheu [153], [154]. U VISSIM-u se koriste dvije inačice navedenog modela prometnog toka (Wiedemann 74 i Wiedemann 99), a temelje se na pretpostavci da se vozač sa svojim vozilom može zateći u četirima različitim stanjima:

- slobodna vožnja – vozač postiže željenu brzinu koju pokušava održavati konstantnom. Na kvalitetu njegove vožnje ne utječu druga vozila već samo tehnička nesavršenost vozila;
- prilaženje – vozač prilagođava brzinu svojeg vozila vozilu koje se nalazi ispred njega. U procesu prilaženja vozač usporava dok se njegova brzina ne izjednači s odnosnim vozilom i ne postigne odgovarajući sigurnosni razmak;
- slijeđenje – vozač slijedi vozilo ispred sebe održavajući siguran razmak bez značajnijih ubrzavanja i usporavanja vozila;
- kočenje – vozač prilikom smanjenja željenog sigurnosnog razmaka naglo ili umjereno usporava svoje vozilo s namjerom ponovnog usklađivanja brzine vožnje.

Vozači prilikom vožnje izmjenjuju navedena stanja u trenucima kada ona prijeđu određeni prag koji je funkcija razlike u brzini i udaljenosti. Doživljaj razlike u brzini vožnje, željenoj brzini i sigurnosnom razmaku među vozačima nije jednak, već ovisi o njihovim psihofizičkim sposobnostima pa se stoga i navedeni model naziva psihofizičkim modelom praćenja vozila. Maksimalno ubrzanje, željeno ubrzanje, maksimalno usporavanje i željeno usporavanje predstavljeni su u VISSIM-u funkcijama distribucije koje je moguće posebno ugađati kako bi čim bolje opisivale ponašanje vozača i karakteristike vozila. Funkcije za maksimalno ubrzavanje i usporavanje za putnička vozila su u osnovi postavljene prema Wiedemann 74

modelu pa ih u načelu nije potrebno mijenjati za potrebe ovoga simulacijskog modela. Svaki entitet, koji predstavlja vozač i njegovo vozilo, može imati različite atribute koje je moguće svrstati u tri osnovne skupine: tehničku specifikaciju vozila, ponašanje kojim se opisuje entitet i međusobna ovisnost vozača i vozila. Uz ugađanje parametara Wiedemannovih modela ponašanja vozača, u VISSIM-u je moguće odrediti i ponašanje pri mijenjanju prometnog traka.

Simulacijski model upućivanja vozila na raspoloživa parkirališna mjesta koristi se Wiedemannovim 74 modelom jer kvalitetnije opisuje ponašanje vozača u gradskim središtima.

6.1.4. Dodjeljivanje prometa

Dodjeljivanje prometa u suštini predstavlja model kojim vozači i općenito putnici odabiru put. Za primjenu takvog modela neophodno je prvo pronaći skup svih mogućih putova, zatim procijeniti sve pronađene alternative i naposljetku, opisati način na koji vozač donosi odluku u skladu s prethodnom procjenom. Kao što je već ranije navedeno, modeliranje te odluke predstavlja poseban slučaj modeliranja diskretnog izbora i većina teorije koja stoji iza dodjeljivanja prometa počiva na teoriji diskretnih izbora.

Razlog modeliranja izbora puta u simulacijskim modelima nalazi se u činjenici da su cestovne mreže koje se simuliraju sve veće i teško je određivati toliko broj statičkih ruta čak i bez razmatranja alternativa ili potrebi da se istraži i procijeni utjecaj promjena cestovne mreže na izbor puta.

Postupak dinamičkog dodjeljivanja temelji se na iterativnoj simulaciji pri kojoj se u svakoj sljedećoj iteraciji koriste iskustva vozača vezana uz ukupne troškove odabranog puta. Dakle, proces je usmjeren na izračunavanje dinamičke stohastičke korisničke ravnoteže. Primjena dinamičkog dodjeljivanja prometa učinkovitija je u apstraktnim prometnim mrežama. Stoga se u tu svrhu i koristi puno apstraktniji prikaz umjesto klasičnog prikaza mreže s poveznicama i priključcima. U tome su prikazu raskrižja sastavljena od priključaka prikazana čvorovima (*nodes*), a povezuju ih rubovi (*edges*) umjesto poveznica.

Prometna potražnja u slučaju dinamičkog dodjeljivanja određuje se OD matricama. Da bi se odredila prometna potražnja simulirano se područje dijeli u zone i matrica tada sadrži broj putovanja u zadanom vremenskom intervalu iz svake pojedine zone u sve ostale zone. Za modeliranje mjesta gdje se vozila pojavljuju i ulaze u prometnu mrežu ili istu napuštaju koriste se parkirališna mjesta jer se u praksi sva putovanja započinju i završavaju na parkirališnom mjestu. Svako parkirališno mjesto pripada određenoj zoni. OD matrice sadrže broj putovanja između svakog para zona u zadanom vremenskom intervalu i vezane su uz određenu kompoziciju vozila. Na slici 24. je prikazan sadržaj jedne OD matrice sa 7 zona. U

prikazanoj matrici iz zone 900 u zonu 2 određeno je 250 putovanja u vremenskom intervalu od 1 sat i 30 minuta.

```
* Vremenski interval
0.00 1.30
* Faktor skaliranja
1
* Broj zona
7
* Identifikatori zona
900 902 1 2 3 901 903
* Broj putovanja između zona
0      0      250    250    250    2000    2000
0      0      200    200    200    1500    1500
0      0      0      0      0      230     220
0      0      0      0      0      230     220
0      0      0      0      0      230     220
0      0      0      0      0      0       0
0      0      0      0      0      0       0
```

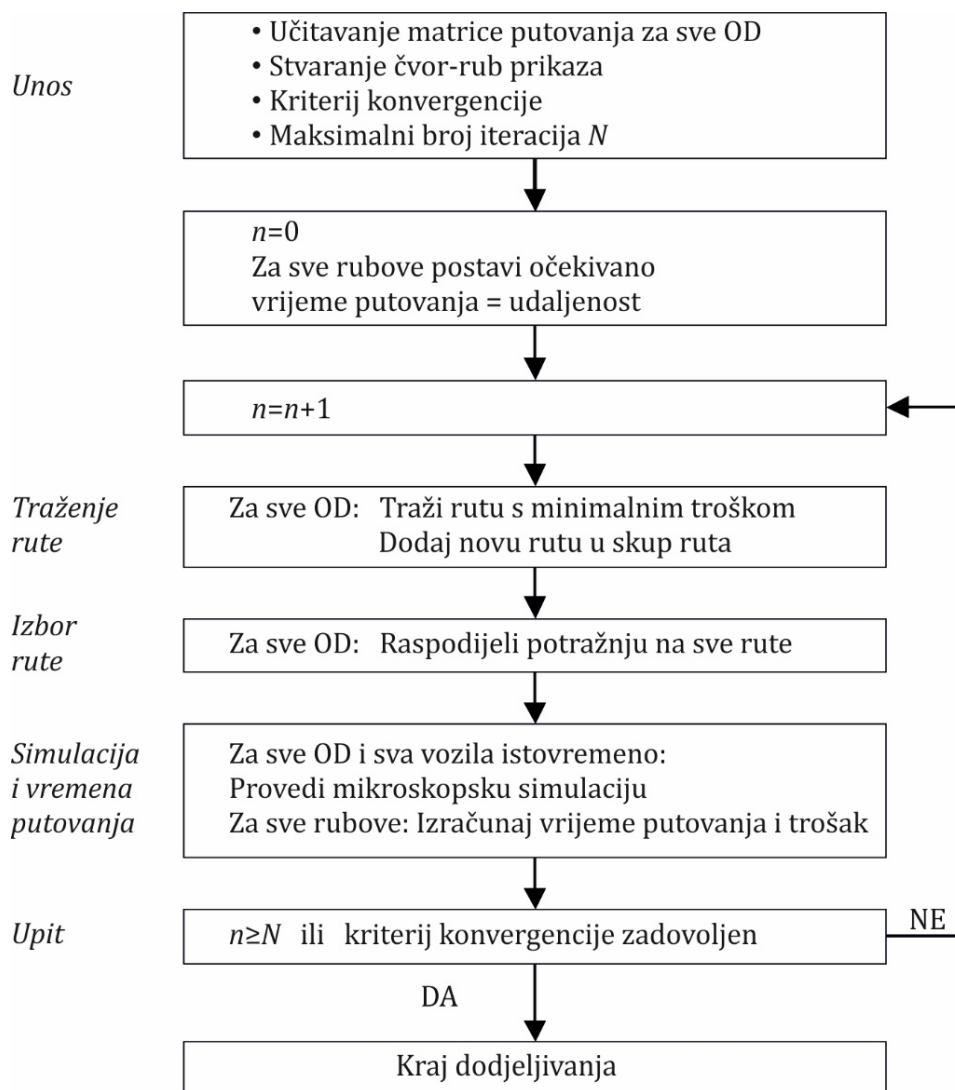
Slika 24. OD matrica

Prometna potražnja može se modelirati i datotekama koje sadrže lance putovanja. Za razliku od OD matrica, lanci putovanja su puno detaljniji, ali zahtijevaju puno više kodiranja. VISSIM interno rukuje samo s lancima putovanja pa se tako sve OD matrice pomoću odgovarajućih algoritama pretvaraju u lance putovanja. U istom se simulacijskom modelu istovremeno mogu koristiti oba pristupa kako bi se generirao prometni volumen i postigla predviđena prometna potražnja. Na slici 25. prikazan je sadržaj datoteke koja sadrži lance putovanja.

```
1.1
1001; 100; 2; 4;1;101;250; 10;3;102;0
1002; 100; 2; 6;1;101;300; 15;3;102;0
1003; 100; 2; 8;1;101;320; 20;3;102;0
1004; 100; 2; 10;1;101;260; 25;3;102;0
1005; 100; 2; 12;1;101;400; 30;3;102;0
1006; 100; 2; 14;1;101;270; 35;3;102;0
1007; 100; 2; 16;1;101;280; 40;3;102;0
1008; 100; 2; 18;1;101;380; 45;3;102;0
1009; 100; 2; 20;1;101;320; 50;3;102;0
1010; 100; 2; 22;1;101;260; 55;3;102;0
1011; 100; 2; 24;1;101;280; 60;3;102;0
1012; 100; 2; 26;1;101;310; 65;3;102;0
1013; 100; 2; 28;1;101;300; 70;3;102;0
1014; 100; 2; 30;1;101;350; 75;3;102;0
1015; 100; 2; 32;1;101;290; 80;3;102;0
1016; 100; 2; 34;1;101;340; 85;3;102;0
```

Slika 25. Primjer lanaca putovanja

Svaki redak datoteke koja sadrži lance putovanja prikazuje svojevrsni opis putovanja jednog vozila u prometnoj mreži gdje prva tri broja predstavljaju broj vozila, tip vozila i ishodišnu zonu, a zatim ih slijede skupine brojeva koji redom predstavljaju vrijeme napuštanja prethodne zone, broj odredišne zone, broj aktivnosti i minimalno vrijeme zadržavanja u odredišnoj zoni.



Slika 26. Princip dinamičkog dodjeljivanja [155]

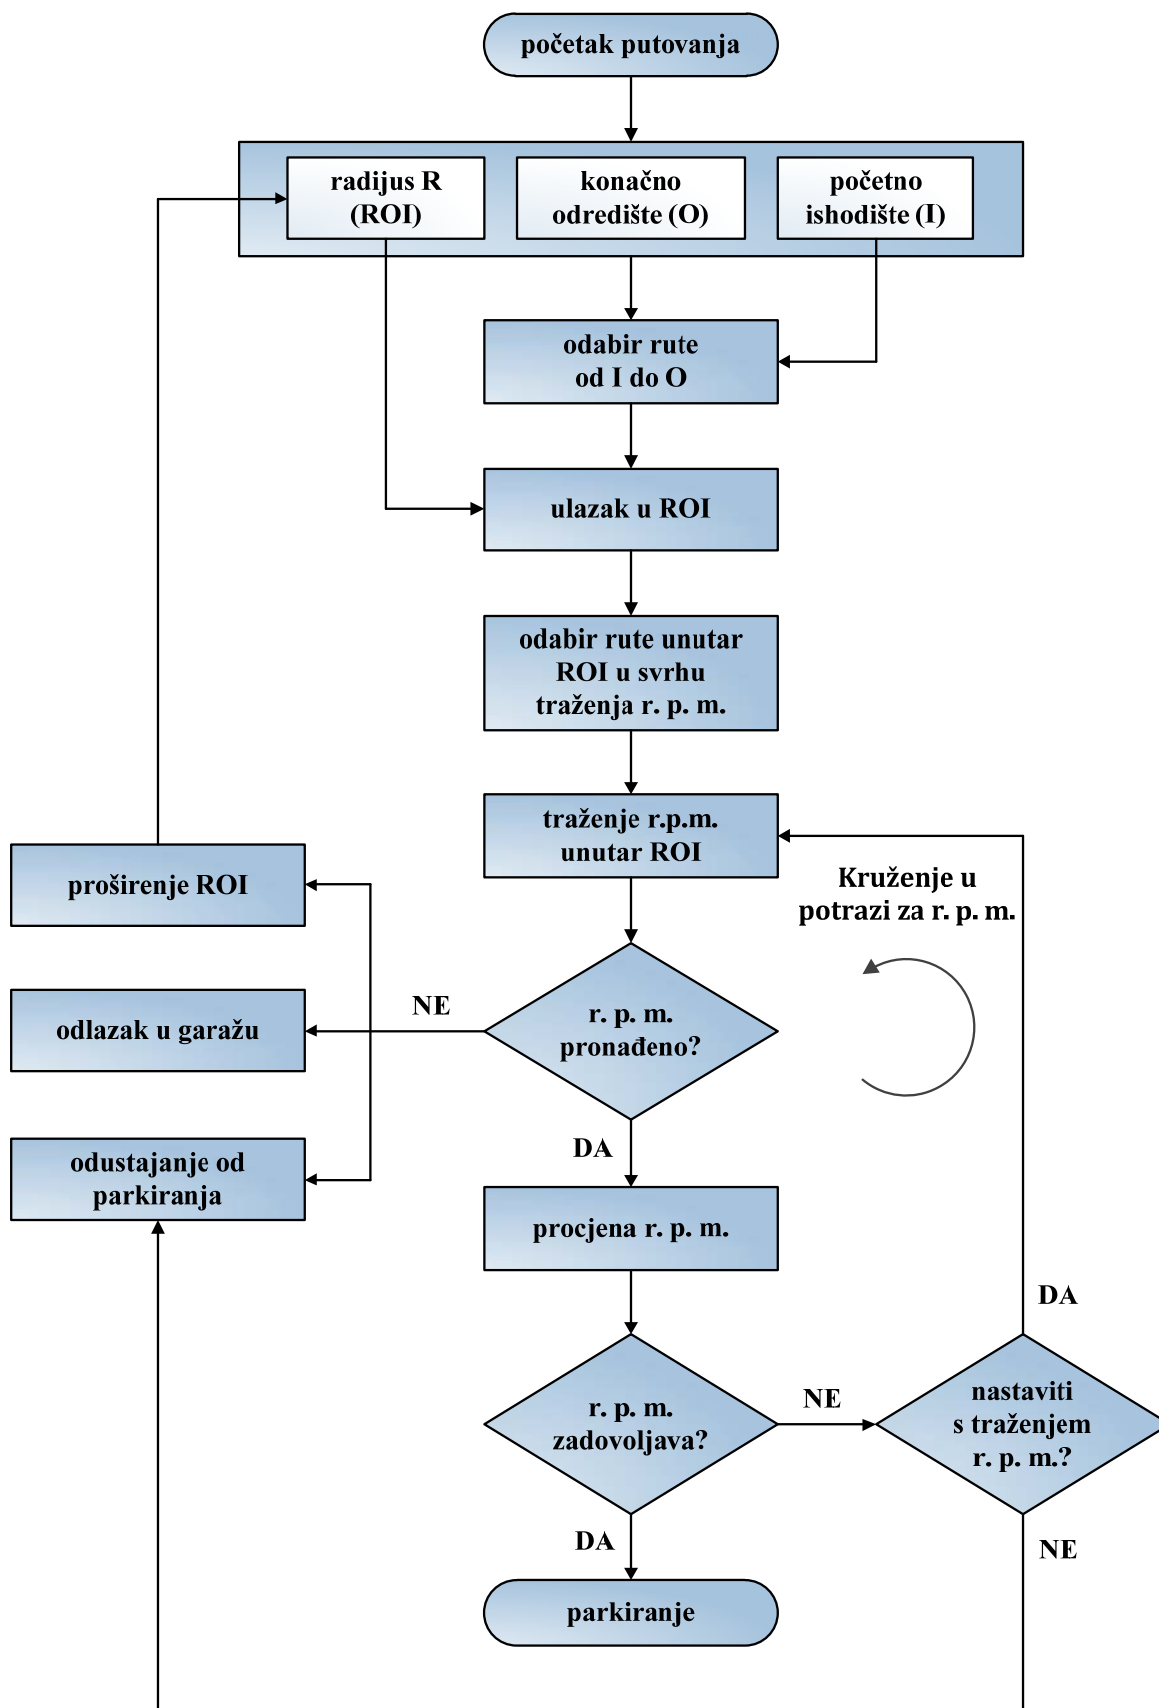
Slika 26. prikazuje način na koji se provodi dinamičko dodjeljivanje prometa u VISSIM-u uz prethodno određene parametre koji opisuju ponašanje modela. Rezultati traženja rute se po potrebi pohranjuju i koriste u iteracijama koje slijede.

6.2. Klasični model traženja raspoloživog parkirališnog mjesta

Dnevne migracije stanovništva u gradskim središtima pogotovo u satima vršnih opterećenja (npr. prilikom odlaska na posao i povratka s radnog mjesta) uzrokuju povećanu parkirališnu potražnju u odnosu na raspoloživu parkirališnu ponudu. Rezultat te pojave je povećanje prometnog toka na okolnim prometnicama zbog kruženja u potrazi za raspoloživim parkirališnim mjestom jer ne postoji odgovarajući sustav koji bi prepoznao slobodna parkirališna mjesta i na odgovarajući način tu informaciju prenio vozačima ili zainteresiranim sudionicima u prometu. S druge strane, bez obzira na tehnološku ekspanziju i sve više vozila koja su opremljena odgovarajućom opremom za navigaciju ta oprema rijetko distribuira dostupne podatke o parkiranju i parkirališnim mjestima vozačima u stvarnom vremenu.

Na slici 27 prikazana je situacija u kojoj osoba koja putuje ne posjeduje uređaj za upućivanje i navigaciju u vozilu. Kada se takva osoba odluči na putovanje, na osnovi svojeg prethodnog iskustva ili prikupljenih informacija dobivenih putem pretputnih sustava informiranja ili ostalih raspoloživih izvora informacija (npr. drugih osoba s odgovarajućim iskustvom), ona pretpostavlja zonu (regiju od interesa, ROI) u blizini odredišta (O) u kojoj će krenuti s potragom za raspoloživim parkirališnim mjestom (r. p. m.) ili odlučuje da će je odrediti naknadno kada se približi odredištu. Pretpostavlja se da će se takvo mjesto prvo tražiti u okviru raspoloživih parkirališnih mjesta na ulici, a tek u slučaju izostanka odgovarajućeg parkirališnog mjesta vozač će se potencijalno odlučiti koristiti izvanulična parkirališta odnosno garaže. Prilikom kretanja na putovanje odabire se ruta koja će se koristiti tijekom putovanja ili se uslijed nepoznavanja puta do odredišta koriste odgovarajući prometni znakovi. Dolaskom u blizinu odredišta i ulaskom u ROI započinje potraga za raspoloživim parkirališnim mjestom odlukom o redoslijedu pretraživanja, odnosno rutama koje će se običi u tu svrhu. Kada je raspoloživo parkirališno mjesto pronađeno, vozač na osnovi svojih želja procjenjuje pronađeno mjesto (cijena, uvjeti parkiranja, itd.) i na osnovu učinjene procjene parkira vozilo ili nastavlja s pretraživanjem.

Postupak se ponavlja sve dok se mjesto ne pronađe i vozilo parkira ili dok se vozač ne odluči na jednu od preostalih mogućnosti, a to su odlazak u garažni objekt, proširenje ROI ili odustajanje od parkiranja. Ponavljanje postupka traženja raspoloživog parkirališnog mjesta upravo predstavlja fenomen kruženja u potrazi za r. p. m. koji je jedan od vodećih negativnih učinaka parkiranja u cijelosti.



Slika 27. Klasični model putovanja, traženja raspoloživog parkirališnog mjesta i parkiranja

6.3. Napredni model sustava za upućivanje vozila na raspoloživa parkirališna mjesta s kooperativnim pristupom

Razvoj gradskih središta uzrokuje i povećanu parkirališnu potražnju. Broj raspoloživih parkirališnih mjesta u gradskim središtima često ne zadovoljava sve potrebe stanovništva i posjetitelja pa je stoga pojava kruženja u potrazi za istima gotovo svakodnevna. Mogućnosti su proširenja parkirališnih kapaciteta ograničene, a izgradnja garaža obuhvaća skupe i zahtjevne građevinske zahvate te opsežnu analizu isplativosti. Odgovorne se osobe pokušavaju na različite načine suprotstaviti tome problemu i uspostaviti ravnotežu između željenog povećanja privlačnosti gradskog središta i neželjenih zagušenja uzrokovanim porastom prometa. Jedan je od najučinkovitijih načina rješavanja problema parkiranja svakako i uporaba sustava za upućivanje vozila na raspoloživa parkirališna mjesta.

U prethodnim su poglavljima prikazani brojni pristupi u rješavanju problema parkiranja uporabom sustava za upućivanje vozila na raspoloživa parkirališna mjesta. Ponuđena se rješenja mogu pronaći u različitim izvedbama koje nude sve više mogućnosti korisnicima sustava i sve su učinkovitije pri pružanju usluga.

Za potrebe istraživanja u sklopu ovoga rada osmišljen je konceptualni model sustava za upućivanje na raspoloživa parkirališna mjesta primjenom kooperativnog pristupa. Predloženi sustav za razliku od sličnih postojećih rješenja temelji svoj rad ponajprije na kooperaciji između OBU i RSU. ATIS informacije koriste se samo u slučajevima kad je to neophodno (nema vozila u komunikacijskom dometu, postoji potreba za povijesnim podacima i sl.) kako bi se postiglo čim učinkovitije dijeljenje informacija. Informacije od osjetila koja su dio prometne infrastrukture obrađuju se na licu mjesta pomoću mikrokontrolera i prosljeđuju direktno sustavu u obližnjem vozilu koje zatim tu informaciju prosljeđuje drugim vozilima u nizu sve dok ona ne pronađe zainteresiranog korisnika. Dakle, i osjetilo kao dio cestovne jedinice i vozilo posjeduju izravnu mogućnost obrade podataka i svojevrsnu inteligenciju tako da se gotovo mogu smatrati mikroračunalnim jedinicama.


Vozilo opremljeno odgovarajućom opremom pri dolasku u zonu komunikacijskog dometa RSU počinje primati raspoložive informacije i prosljeđivati ih ostalim vozilima oko sebe. Istovremeno se ta informacija ovisno o komunikacijskim mogućnostima prosljeđuje i u ATIS. Na osnovi navedene kooperacije između vozila i RSU prenose se i informacije o raspoloživosti parkirališnih mjesta. Vozilo prilikom ulaska u ulicu ili određeno uže gradsko područje (jedan ili više stambenih blokova) u kojoj se nalaze parkirališna mjesta unaprijed

zna gdje se može parkirati, te se time smanjuje potreba za bespotrebnim kruženjem u potrazi za raspoloživim parkirališnim mjestom.

6.3.1. Opis naprednog modela s kooperativnim pristupom

U drugom slučaju kada je vozilo opremljeno uređajem za upućivanje na raspoloživo parkirališno mjesto primjenom kooperativnog pristupa osoba koja putuje dobiva sve potrebne informacije neposredno prije samog putovanja (Slika 28.). Ako postoji bilo kakva neizvjesnost o putovanju, osoba može pomoću ATIS-a dobiti sve potrebne pretputne informacije kako bi kvalitetnije isplanirala putovanje. Sustav u vozilu na početku putovanja određuje poziciju ishodišta i odredišta na osnovi GNSS podataka i traži najpovoljniju rutu ovisno o trenutnoj prometnoj situaciji i postavljenim kriterijima (vozač recimo ne želi koristiti autoceste). Pronađenu optimalnu rutu prikazuje na zaslonu uređaja vozaču. Ako se vozač iz bilo kojeg razloga odluči promijeniti svoj itinerer putovanja (npr. želi od ishodišta do odredišta doći obilaskom nekog međuodredišta), sustav ponavlja postupak i traži novo optimalno rješenje.

Nakon što se pronađe odgovarajuća ruta putovanja vozač putuje prometnim dionicama uz kontinuirano praćenje prometne situacije. Kooperativni sustav u vozilu kontinuirano prikuplja raspoložive informacije od osjetila u vozilu, RSU i ATIS-a kako bi mogao pravovremeno reagirati u slučaju potrebe. Tijekom cijelog vremena putovanja vozaču se nude razne korisne informacije poput ograničenja brzine, prometnih gužvi na pojedinim dionicama, pozicije benzinskih postaja, odmorišta, parkirališnih mjesta, raznih objekata (restorana, hotela, kazališta, bolnica i sl.). Na temelju dobivenih informacija vozač može promijeniti svoju prethodnu odluku i odabrati mjesto na kojem će se zaustaviti na putu do odredišta. U tom se slučaju sustav prilagođava novonastaloj situaciji i ponovno traži optimalnu rutu kako bi vozača doveo na odabrano mjesto. Ovaj se postupak može potaknuti i drugim događajima. Na primjer, ako se prilikom dolaska na prethodno odabrano raspoloživo parkirališno mjesto dogodi situacija da ga drugi vozač zauzme, tada će sustav na osnovi novog odabira promijeniti rutu putovanja. Naravno, ovakav je scenarij moguć jedino ako ne postoji mogućnost rezervacije raspoloživog parkirališnog mjesta i ako algoritmi za predviđanje vjerojatnosti raspoloživosti parkirališnog mjesta u određenom vremenskom intervalu nisu bili dovoljno uspješni. Za razliku od prethodnog slučaja ovdje ne postoji potreba za bilo kakvim kruženjem jer je vozač unaprijed informiran o svim raspoloživim mogućnostima.



Slika 28. Napredni model putovanja, traženja raspoloživog parkirališnog mjesta i parkiranja s kooperativnim pristupom



Slika 29. Kooperativno djelovanje RSU, OBU i ATIS-a

Napredni model čije je djelovanje prikazano na slici 29 ovisi o kvalitetnim stvarnovremenskim informacijama koje prije svega pružaju osjetila u sklopu RSU-a. Stoga RSU mora biti robusna, imati male zahtjeve za održavanjem i visoku raspoloživost, a komunikacija s ostalim jedinicama sustava treba biti sigurna i postojana. Komunikacija s ATIS-om neophodna je samo za slučajeve kada postoji potreba za povijesnim podacima ili rezultatima dugotrajnih analiza kao što je to navedeno u poglavlju 4.3.

6.3.2. Vrijeme putovanja i ukupni troškovi

Kod dinamičkog dodjeljivanja prometna potražnja i mrežna infrastruktura tijekom vremena nisu konstantne. Stoga se prometna situacija, a time i vremena putovanja mijenjaju u razdoblju dodjeljivanja prometa. Ukupno vrijeme simulacije dijeli se na manje evaluacijske intervale kako bi se jednostavnije mogla razmatrati vremena putovanja. Oni ne bi trebali biti manji od 5 minuta niti veći od polovice vremenskog intervala određenog OD matricom.

U vrijeme simulacije mjere se vremena putovanja posebno za svaki rub mreže (put između dvaju čvorova). Svako vozilo pri napuštanju određenog ruba izvještava o utrošenom vremenu, a zatim se izračunava prosjek svih vremena putovanja provedenih na tom rubu koji tada predstavlja rezultirajuće vrijeme putovanja. Posebna se pažnja posvećuje vozilima

koji se zadržavaju na nekom rubu duže od trajanja evaluacijskog razdoblja jer je to znak za prisustvo zagušenja. Ta vozila izvještavaju i o vremenu trajanja zastoja. Izmjerena vremena putovanja ne koriste se u svrhu traženja i izbora puta u istoj iteraciji već utječu na sljedeću.

VISSIM omogućuje korištenje ne samo vremena putovanja iz iteracije koja je neposredno prethodila trenutnoj, već i svih ostalih ranijih iteracija i to na dva načina:

1. eksponencijalnim zaglađivanjem – korisnik određuje čimbenik zaglađivanja kojim se izračunava utjecaj prethodnih iteracija tako da najstarije iteracije imaju najmanji utjecaj
2. MSA – izračunava aritmetičke sredine svih iteracija i na osnovi toga određuje težinski čimbenik. Što je veći broj iteracija koje se uzimaju u obzir to je manji utjecaj svake sljedeće iteracije.

Zaglađeno vrijeme putovanja izračunava se iz dobivenog skupa vrijednosti kao ponderirani zbroj stare zaglađene vrijednosti prethodne iteracije i nove izmjerene vrijednosti trenutne iteracije. Dobivena zaglađena vrijednost predstavlja vrijeme putovanja koje se očekuje u sljedećoj iteraciji. Vrijeme putovanja za određeni rub, mjereno u vremenskom intervalu jedne iteracije, eksponencijalno se zaglađuje prije donošenja odluke o izboru rute na način

$$T_{a_r}^{n,K_{ei}} = (1 - \alpha_z) \cdot T_{a_r}^{n-1,K_{ei}} + \alpha_z \cdot TO_{a_r}^{n,K_{ei}}, \quad (42)$$

gdje su:

K_{ei} – indeks evaluacijskog intervala u razdoblju simulacije

n – indeks iteracije dodjeljivanja

a_r – indeks ruba

$TO_{a_r}^{n,K}$ – izmjereno vrijeme putovanja na rubu a za period k u iteraciji n

$T_{a_r}^{n,K}$ – očekivano vrijeme putovanja na rubu a za period k u iteraciji n

α_z – parametar zaglađivanja.

Očekivano se vrijeme putovanja uporabom MSA (vidi potpoglavlje 5.2.) izračunava na sljedeći način

$$T_{i_r}^{n,K_{ei}} = \left(1 - \frac{1}{N + n}\right) \cdot T_{i_r}^{n-1,K_{ei}} + \frac{1}{N + n} \cdot TO_{i_r}^{n,K_{ei}}, \quad (43)$$

gdje su:

- N – korisnički određena vrijednost
- K_{ei} – indeks evaluacijskog intervala u periodu simulacije
- n – indeks iteracije dodjeljivanja
- i_r – indeks ruba
- $TO_i^{n,K}$ – izmjereno vrijeme putovanja na rubu i za period k u iteraciji n
- $T_i^{n,K}$ – očekivano vrijeme putovanja na rubu i za period k u iteraciji n
- $\frac{1}{N+n}$ – promjenjivi čimbenik zaglađivanja ovisan o parametru N i indeksu iteracije dodjeljivanja.

Vrijeme putovanja nije jedini čimbenik koji utječe na izbor puta. Funkcija općih troškova je linearna kombinacija vremena putovanja, dužina putovanja i financijskog troška kao što je cestarina. Za razliku od vremena putovanja ovi čimbenici ne ovise o prometnoj situaciji i ne određuju se simulacijom. Težina komponenata troška može se posebno odrediti za svaku klasu vozila koju je korisnik prethodno generirao. Da bi se navedena tri čimbenika uzela u obzir pri izboru puta izračunava se opći trošak C za svaki pojedini rub kao ponderirani zbroj

$$C = \alpha \cdot t + \beta \cdot s + \gamma \cdot C_f + \sum C_{n2}, \quad (44)$$

gdje su:

- α, β i γ – težinski čimbenici kojima se može po potrebi odrediti različito ponašanje skupine vozača pri izboru rute
- s – čimbenik određen geometrijom prometnih dionica
- C_f – zbroj troškova svih prometnih dionica koje čine jedan rub. Trošak prometne dionice je umnožak njezine dužine u kilometrima s troškom po kilometru dužine određenim u njezinim parametrima. U navedeni trošak spada i vrijednost parametra nadoplata 1 (*surcharge1*)
- C_{n2} – dodatni trošak prometne dionice (nadoplata 2) koji nije opterećen čimbenikom γ .

6.3.3. Traženje i izbor odgovarajuće rute

Ruta je niz rubova koji opisuje put kroz mrežu. Rute počinju i završavaju na parkirališnom mjestu. Opći trošak rute određen je općim troškovima svih njegovih rubova

$$C_R = \sum_{a \in R} C_a, \quad (45)$$

gdje su:

C – opći trošak

R – ruta

a – rub koji pripada ruti R .

Između ishodišnog i odredišnog parkirališnog mjesta obično ima više od jednog mogućeg puta, stoga se pomoću VISSIM-a modelira odluka vozača o izboru puta. U sklopu dinamičkog dodjeljivanja VISSIM računa broj raspoloživih putova i provodi odabir. Izbor puta je poseban slučaj diskretnog izbora jer vjerojatnosti izbora alternativa moraju biti izračunate za dani skup diskretnih alternativa. Kod dinamičkog dodjeljivanja skup raspoloživih ruta može se prikazati i skupom parova ishodište-odredište.

Ne postoji učinkovit algoritam za pronalaženje n najboljih ruta za svaki OD par, ali postoji mogućnost pronalaska jedne najbolje rute. U svakoj iteraciji dinamičkog dodjeljivanja traži se najbolja ruta za svaki OD par čime se rješava prethodno spomenuti problem jer se uslijed prometne situacije mijenjaju vremena putovanja od iteracije do iteracije dok se ne zadovolji kriterij konvergencije. Na taj će se način pronaći više različitih "najboljih" ruta koje će VISSIM spremiti u datoteku s ekstenzijom *.weg* kako bi ostale raspoložive za buduće iteracije.

Kriterij za izbor najbolje rute je opći trošak. Uslijed činjenice da koeficijent ponderiranja općih troškova ovisi o tipu vozila bit će pronađeni različiti najbolji putovi za različite tipove vozila. U prvoj iteraciji ne postoji informacija o vremenu putovanja iz prethodnih iteracija pa se stoga umjesto vremena putovanja koristi dužina puta izražena u metrima. Skup poznatih putova puno će brže rasti ako se vozače na neki način ohrabri da isprobaju nove putove. U tu se svrhu u sljedećim iteracijama rubovima kojima nije prolazilo vozilo fiktivno dodaje vrijeme putovanja od 0,1 sekunde kako bi se povećala njihova atraktivnost prilikom traženja rute. Ipak, ovaj postupak može dovesti do pridruživanja beskorisnih ruta skupu kojeg se generira. Beskorisne rute su one rute koje zamjenjuju bilo koju od poznatih postojećih ruta nizom poveznica s puno većom dužinom pa se one smatraju očitim obilaznicama. Dužinu niza poveznica koja će rutu kvalificirati kao obilaznicu određuje korisnik.

Kod dinamičkog dodjeljivanja vozači odabiru rutu u trenutku napuštanja ishodišnog parkirališnog mjesta. Jedna od osnovnih pretpostavki pri odabiru puta u VISSIM-u je da neće svi vozači koristiti najbolji put već će koristiti sve poznate putove na način da će veći prometni udio biti distribuiran boljim putovima. Kvaliteta puta se evaluira pomoću općih troškova koji su u suprotnosti s korisnošću koja je dio teorije diskretnog odlučivanja. Stoga se korisnost određuje kao recipročna vrijednost općih troškova

$$U_j = \frac{1}{C_j}, \quad (46)$$

gdje su:

U_j - korisnost puta j

C_j - opći troškovi puta j .

Funkcija koja se najčešće koristi za ponašanje pri izboru rute je Logit funkcija (vidi poglavlje 5.3.)

$$p(R_j) = \frac{e^{\mu U_j}}{\sum e^{\mu U_i}}, \quad (47)$$

gdje su:

U_j – korisnost puta j

$p(R_j)$ – vjerojatnost odabira puta j

μ – parametar osjetljivosti modela (>0).

Mala će vrijednost parametra osjetljivosti rezultirati distribucijom bez većeg utjecaja korisnosti, dok će velika vrijednost rezultirati time da će gotovo svaki vozač odabrati najbolji put. Ako se Logit funkcija koja je translacijski nepromjenjiva primjeni uz prethodno navedenu funkciju troškova, model će istu važnost dodijeliti malim razlikama između vremena putovanja kod malih vrijednosti kao i kod relativno velikih (npr. puno značajnija razlika u vremenima putovanja od 11 i 8 minuta poistovjetit će se s gotovo zanemarivom razlikom putovanja od 116 i 113 minuta). Kako bi se aproksimirala stvarna procjena i distribuirala prometna potražnja svim poznatim rutama skupa OD parova, VISSIM koristi Kirchhoffovu formulu distribucije

$$p(R_j) = \frac{U_j^{k_o}}{\sum_i U_i^{k_o}}, \quad (48)$$

gdje su:

U_j – korisnost puta j

$p(R_j)$ – vjerojatnost odabira puta j

k_o – parametar osjetljivosti modela.

U ovom obliku omjer korisnosti određuje distribuciju, a ne predstavlja apsolutnu razliku korisnosti. To znači da će u prethodno navedenom slučaju biti mala razlika u dodjeljivanju prometa za putove čije je vrijeme putovanja 116 i 113 minuta, ali će se puno više prometa usmjeriti na put čije je vrijeme putovanja 8 minuta nego na put koji traje 11 minuta.

Kirchhoffova formula distribucije se može izraziti u obliku Logit funkcije ako se funkcija korisnosti prikaže u logaritamskom obliku

$$p(R_j) = \frac{U_j^{k_o}}{\sum_i U_i^{k_o}} = \frac{e^{k_o \cdot \log U_j}}{\sum_i e^{k_o \cdot \log U_i}} = \frac{e^{-k_o \cdot \log C_j}}{\sum_i e^{-k_o \cdot \log C_i}}, \quad (48)$$

gdje je C_j opći trošak rute j .

Za odstupanje distribucije pri preklapajućim rutama VISSIM nudi proširenje modela izbora rute čimbenikom istovjetnosti (vidi potpoglavlje 5.10.).

6.3.4. Izbor parkirališnog mjesta

Prometna potražnja u OD matricama odnosi se na zone koje su određene za ishodište i odredište. Zone su u VISSIM-u predstavljene s jednim ili više parkirališta. Ako se na odredištu nalazi više parkirališnih mjesta vozač mora odabrati parkirališno mjesto prije izbora puta. Odabir parkirališnog mjesta je još jedan primjer u kojem se koristi teorija diskretnih izbora. I u ovom se slučaju koristi Logit formula i funkcija korisnosti s atributima parkirališnih mjesta.

Pri dinamičkom se dodjeljivanju u VISSIM-u koriste tri tipa parkirališta:

- priključak zone (*zone connector*) – ovim tipom parkirališta modelira se ulazak i izlazak vozila u i iz prometne mreže, odnosno mjesta ishodišta i odredišta u prometnoj mreži. Vozilo ulazi i izlazi iz prometne mreže bez kašnjenja i zaustavljanja

i najčešće se koristi na rubovima simulacijskog modela. Kapacitet priključka zone nije ograničen.

- apstraktno parkiralište (*abstract parking lot*) – vozila usporavaju prilikom prilaska parkiralištu i zaustavljaju se u sredini određenog prostora. Nakon zaustavljanja i parkiranja se brišu iz prometne mreže. Zbog modeliranja zaustavljanja ovaj je tip parkirališta ograničen na 700 voz/h.
- stvarna parkirališna mjesta (*real parking space*) – za stvarna se parkirališna mjesta odluka o parkiranju smješta 50 m prije parkirališta na početku simulacije. Izračunata ruta kod dinamičkog dodjeljivanja (potpoglavlje 6.1.4.) također može koristiti ovaj tip parkirališta.

Odabir parkirališnog mjesta može biti dio aktivnosti sljedećih scenarija:

- vozilo započinje putovanje s ishodišnog parkirališnog mjesta,
- odabir parkirališnog mjesta započet je odlukom dinamičkog rutiranja,
- odabir parkirališnog mjesta započet je sustavom za upućivanje vozila i navigaciju.

Broj raspoloživih alternativa i parametar funkcije korisnosti mogu biti različiti za svaki navedeni scenarij (*Decision Situation*). U prvom je scenariju broj raspoloživih parkirališnih mjesta ovisan o odredišnoj zoni i njezinim raspoloživim kapacitetima dok se u druga dva scenarija isti mijenja ovisno o postavljenim strategijama (Slika 30.).

Dynamic Vehicle Routing Decisions											
Select layout... <Single List>											
Count	No	Name	Link	Pos	AllVehTypes	VehClasses	Condition	CondParkLot	AvailSpaces	Strategy	StratParkLot
1	1	20	12.141		<input type="checkbox"/>	70	Always			0 Any zone, different parking lot by benefit	<input checked="" type="checkbox"/>
2	2	42	9.524		<input type="checkbox"/>	70	Always			0 Any zone, different parking lot by benefit	<input checked="" type="checkbox"/>
3	3	46	7.518		<input checked="" type="checkbox"/>		Destination parking lot full			0 Same zone, different parking lot by benefit	<input checked="" type="checkbox"/>
4	4	34	15.809		<input checked="" type="checkbox"/>		Destination parking lot full			0 Same zone, different parking lot by benefit	<input checked="" type="checkbox"/>
5	5	1	13.007		<input type="checkbox"/>	70	Always			0 Any zone, different parking lot by benefit	<input checked="" type="checkbox"/>
6	6	42	30.056		<input checked="" type="checkbox"/>		Destination parking lot full			0 Any zone, parking lot by benefit function	<input checked="" type="checkbox"/>
7	7	46	22.521		<input checked="" type="checkbox"/>		Destination parking lot full			0 Any zone, parking lot by benefit function	<input checked="" type="checkbox"/>
8	8	47	16.083		<input type="checkbox"/>	10,70	Destination parking lot full			0 Same zone, different parking lot by benefit	<input checked="" type="checkbox"/>
9	9	43	48.271		<input type="checkbox"/>	10	Destination parking lot full			0 Same zone, different parking lot by benefit	<input checked="" type="checkbox"/>

Slika 30. Primjeri dinamičkog odlučivanja o rutama vozila

Funkcija korisnosti za parkirališno mjesto dana je izrazom

$$U_{k_{tv},k_s} = \alpha_{k_{tv},k_s} \cdot C_{Parking} + \beta_{k_{tv},k_s} \cdot Z + \gamma_{k_{tv},k_s} \cdot D_{odr} + \delta_{k_{tv},k_s} \cdot C_{voz} + \varepsilon_{k_{tv},k_s} \cdot f_s, \quad (49)$$

gdje su:

$C_{Parking}$ – cijena parkiranja u zoni

Z – privlačnost karakteristika promatrane zone

- D_{odr} – zračna udaljenost između centra odredišne zone i parkirališnog mjesta (udaljenost od odredišne zone)
- C_{voz} – opći troškovi najjeftinije rute od trenutne pozicije vozila (udaljenost od trenutne lokacije)
- f_s – raspoloživost slobodnih parkirališnih mjesta
- k_{tv} – indeks tipa vozila
- k_s – indeks scenarija.

Korisnik određuje pozitivne koeficijente funkcije korisnosti β_{k_{tv}, k_s} i $\varepsilon_{k_{tv}, k_s}$ i negativne koeficijente funkcije korisnosti α_{k_{tv}, k_s} , γ_{k_{tv}, k_s} i δ_{k_{tv}, k_s} za svaki scenarij zasebno.

Na osnovi trenutne situacije u simulacijskom modelu i prethodno postavljenih kriterija dinamički se određuje parkirališno mjesto za vozila koja ulaze u modeliranu prometnu mrežu. U slučaju da jedno od vozila bez RG zauzme parkirališno mjesto koje je određeno za vozilo s RG-om, vozilo s RG-om odabire novo raspoloživo parkirališno mjesto i preračunava odgovarajuću rutu do istog upotrebom istih algoritama kao i u trenutku ulaska u prometnu mrežu simulacijskog modela.

7. EVALUACIJA USPJEŠNOSTI NAPREDNOG MODELA ZA UPUĆIVANJE VOZILA

Učinkovitost uporabe sustava za upućivanje na raspoloživa parkirališna mjesta može se iskazati ukupnim vremenom putovanja, ukupnim prijeđenim putom i ukupnim troškovima putovanja koji mogu uključivati i sve težinske koeficijente proporcionalno pretvorene u trošak. U svrhu prikazivanja učinkovitosti sustava za upućivanje na raspoloživa parkirališna mjesta s kooperativnim pristupom uključena su sva tri čimbenika kao reprezentativni pokazatelji.

7.1. Opis simulacijskog modela

Simulacijski model napravljen u VISSIM-u obuhvatio je sve karakteristike modela sustava cestovnog prometa opisane u poglavlju 6 kako bi čim kvalitetnije predstavio situaciju i uvjete koji vladaju u zagušenim gradskim središtima. Simulacija je provedena u trajanju od 90 minuta s namjerom da se simuliraju vršna opterećenja apstraktnog gradskog središta. Stoga se model ugađanjem i kalibracijom doveo u stanje graničnog opterećenja s velikim prometnim volumenom kako bi se čim više naglasio negativni učinak kruženja za slobodnim parkirališnim mjestom. Nakon postizanja stanovitog stupnja ravnoteže provedena je simulacija za svaki pojedini scenarij s time da su se rezultati prvih 30 minuta uklanjali jer je to vrijeme potrebno za popunjavanje mreže vozilima i postizanje potrebne ravnoteže. Simulacija je provedena za četiri različita scenarija:

1. parkiranje vozila bez sustava za upućivanje na raspoloživa parkirališna mjesta,
2. parkiranje vozila s 10 % vozila opremljenih sustavom za upućivanje na raspoloživa parkirališna mjesta (10 % RG),
3. parkiranje vozila s 25 % vozila opremljenih sustavom za upućivanje na raspoloživa parkirališna mjesta (25 % RG),
4. parkiranje vozila s 50 % vozila opremljenih sustavom za upućivanje na raspoloživa parkirališna mjesta (50 % RG).

Broj vozila koja su tražila raspoloživo parkirališno mjesto predstavljao je 20 % ukupnog induciranog prometnog volumena. Sva su raskršća postavljena kao čvorovi s dodijeljenim prometnim pravilima prioriteta i reguliranim brzinama skretanja ili s promjenjivom svjetlosnom signalizacijom. Vozila su u simulacijski model učitavana na tri moguća ulazna prometna toka, a napuštali su ga putem triju izlaznih prometnih tokova. Time je određeno 9

mogućih ulazno-izlaznih kombinacija u simulacijskom modelu nazvanih smjerovima i označenih brojevima od jedan do devet.

Broj vozila se tijekom iteracija nije značajno mijenjao jer je ovisio samo o graničnom zagušenju koje se rijetko pojavljivalo i nije dozvoljavalo ulazak novog vozila u mrežu. Osnovni prometni tok činila su gospodarska i osobna vozila koja su bila sastavljena od 7 različitih modela (Volkswagen Golf, Audi A4, Mercedes CLK, Peugeot 607, Volkswagen Beetle, Porsche Cayman i Toyota Yaris).

Vozilima je prilikom ulaska u model dodijeljivano odredišno parkirališno mjesto, ako ista nisu služila za generiranje osnovnog prometnog volumena. U slučajevima kada je odredišno parkirališno mjesto bilo zauzeto započeo je postupak traženja raspoloživog parkirališnog mjesta koji je trajao dok se vozilo ne uspije parkirati ili mu istekne maksimalno dozvoljeno vrijeme izvršavanja zadatka.

Za potrebe ovog istraživanja koristilo se šest priključaka zona podijeljenih na istočne i zapadne, kako bi se kontrolirala prometna potražnja, i 578 stvarnih parkirališnih mjesta podijeljenih u tri parkirališne zone. Područje od interesa u apstraktnom modelu zamišljeno je u sredini iznad prometne mreže pa su u skladu s time određene i zone parkiranja te atraktivnost Z pojedinih parkirališnih mjesta. Simulacijski model općenito prikazuje zamišljeno gradsko središte pa je i zauzetost parkirališnih mjesta na parkiralištima određena na osnovi mjerenja provedenih u gradu Zagrebu. Normalna raspodjela opisuje vrijeme parkiranja i smještanja na parkirališno mjesto sa srednjom vrijednošću $\mu = 30$ i standardnom devijacijom $\sigma = 2$. Dužina parkirališnih mjesta je definirana na 6 m. Parkirališta se nisu ograničavala cijenom i radnim vremenom te maksimalnim trajanjem parkiranja.

U svrhu simulacije postavljeni su još i sljedeći parametri dinamičkog dodjeljivanja:

- evaluacijski interval: 1,800 s
- troškovi se pohranjuju uporabom MSA
- broj putova je ograničen na 999 za svaki OD par
- putovi s ukupnim troškom višim od 75 % najboljeg puta se odbacuju
- putovi i prometni volumeni se pohranjuju uporabom Kirchhoffovog eksponenta od 2,5, Logit čimbenika skaliranja od 1,5 i donje granice 0,005
- korekcija preklapanja putova
- obilazni putovi koji su 2,5 puta veći od najboljeg puta se odbacuju

- kriterij konvergencije za vrijeme putovanja na rubovima postavljen je tako da varijanca vremena putovanja bilo kojeg ruba nije veća od 2 %.

Nakon provedene simulacije za zagušeni prometni tok postupak je ponovljen za prometni tok bez zagušenja.

7.2. Ispitivanje i ocjena uspješnosti simulacijskog modela

Uspješnost simulacijskog modela ispitivala se i ocijenila pomoću već navedenih kriterija, a to su vrijeme putovanja, prijedeni put i ukupni troškovi. Evaluacijom je obuhvaćeno svih devet prometnih smjerova. Vrijeme putovanja promatrano je za ukupan broj vozila u simulacijskom modelu pod uvjetima zagušenja u vršnim opterećenjima gradskih središta i pri protočnom prometnom toku bez zagušenja za devet prometnih smjerova, dok su ostali čimbenici uspješnosti ocijenjeni na osnovi ukupnog broja vozila u navedenim slučajevima.

7.2.1. Vrijeme putovanja

Jedno od osnovnih elemenata mjerenja učinka u brojnim transportnim analizama je vrijeme putovanja, koje se koristi ne samo prilikom evaluacije već i pri planiranju, oblikovanju i djelovanju transportnih sustava. Ono je kritična informacija svih naprednih transportnih informacijskih sustava. Vrijeme putovanja ovisno je o brzini vozila, prometnom toku i karakteristikama vozača te je posebno osjetljivo na uvjete na prometnici i prometne incidente. Djelovanje sustava za upućivanje i navigaciju nezamislivo je bez preciznog predviđanja vremena putovanja, no uzevši u obzir prethodno navedene čimbenike jasno je da je postizanje optimalne preciznosti veoma zahtjevno i složeno.

Brzina vožnje (v), ubrzavanje ($a > 0$) i usporavanje ($a < 0$) vozila su u VISSIM-u određeni funkcijama koje su opisane s trima krivuljama (minimalnim, maksimalnim i referentnim vrijednostima) kako bi se omogućila stohastička distribucija vrijednosti. Brzina vozila u simulacijskom modelu jednaka je referentnoj brzini ako je prometna traka slobodna uz neznatne stohastičke oscilacije. Kada se to vozilo približi drugom sporijem vozilu pokušat će ga zaobići manjom referentnom brzinom, ako za to postoje uvjeti, poštujući sva prometna pravila i ograničenja (vidi potpoglavlje 6.1.3.). Referentna brzina u ovome simulacijskom modelu određena je s 50 km/h.

U tablicama 7, 8, 9 i 10 prikazani su statistički pokazatelji vremena putovanja za pojedine scenarije (minimalno vrijeme putovanja t_{\min} , maksimalno vrijeme putovanja t_{\max} , srednje vrijeme putovanja t_{sr} i standardna devijacija σ_t) te pojedine smjerove u simulacijskom modelu u slučaju visoke razine zagušenja prometnica (~6000 vozila).

Tablica 7. Statistički pokazatelji za slučaj bez RG

Smjer	Broj vozila N	Vrijeme t [s] provedeno u mreži	t_{\min} [s]	t_{\max} [s]	t_{sr} [s]	σ_t [s]
1.	413	149838,00	226,02	296,66	249,72	25,54
2.	1250	187814,00	201,16	506,34	313,02	104,60
3.	419	83646,00	115,20	176,20	139,42	22,44
4.	420	166318,00	210,12	398,72	277,20	66,32
5.	459	97908,00	116,66	224,26	163,18	36,04
6.	906	140718,00	178,66	277,80	234,54	33,22
7.	596	85540,00	77,72	307,26	142,56	89,52
8.	646	196192,00	202,96	506,46	326,98	116,28
9.	850	61428,00	80,50	140,40	102,38	23,94
Ukupno:	5959	1169402,00				

Tablica 8. Statistički pokazatelji za slučaj s 10 % RG

Smjer	Broj vozila N	Vrijeme t [s] provedeno u mreži	t_{\min} [s]	t_{\max} [s]	t_{sr} [s]	σ_t [s]
1.	414	150904,00	211,52	305,18	251,50	36,06
2.	1282	177658,00	171,88	368,36	296,10	66,92
3.	414	81744,00	114,42	165,44	136,24	17,54
4.	437	160278,00	209,08	385,02	267,14	63,76
5.	471	113976,00	150,22	228,40	189,96	33,88
6.	907	132962,00	180,14	250,14	221,60	23,96
7.	630	73486,00	95,18	157,66	122,48	26,02
8.	647	198862,00	220,76	423,18	331,44	81,28
9.	850	60588,00	71,62	119,50	100,98	17,70
Ukupno:	6052	1150458,00				


Tablica 9. Statistički pokazatelji za slučaj s 25 % RG

Smjer	Broj vozila N	Vrijeme t [s] provedeno u mreži	t_{\min} [s]	t_{\max} [s]	t_{sr} [s]	σ_t [s]
1.	417	150886,00	204,20	280,30	251,48	28,18
2.	1290	152026,00	182,16	317,90	253,38	46,06
3.	409	78168,00	114,74	167,24	130,28	20,36
4.	444	158756,00	223,68	323,46	264,60	43,34
5.	457	108676,00	150,98	213,98	181,12	26,92
6.	910	130708,00	183,28	246,68	217,84	25,68
7.	619	67336,00	88,18	131,98	112,22	17,42
8.	653	171264,00	190,78	369,58	285,44	58,88
9.	853	60164,00	80,36	125,86	100,28	18,82
Ukupno:	6087	1077984,00				


Tablica 10. Statistički pokazatelji za slučaj s 50 % RG

Smjer	Broj vozila N	Vrijeme t [s] provedeno u mreži	t_{\min} [s]	t_{\max} [s]	t_{sr} [s]	σ_t [s]
1.	417	181546,00	252,54	546,79	453,86	135,98
2.	1290	107597,00	142,34	486,78	268,99	174,81
3.	419	103518,00	77,11	481,00	258,80	228,89
4.	444	213921,00	126,16	929,29	534,80	401,73
5.	471	87163,00	88,38	416,74	217,91	161,52
6.	910	70359,00	97,37	159,72	131,37	27,15
7.	630	60536,00	67,73	305,56	151,34	110,37
8.	653	161444,00	116,03	751,36	403,61	303,78
9.	853	30714,00	53,27	106,06	70,01	32,06
Ukupno:	6087	1016798,00				

Ukupno vrijeme putovanja, odnosno ukupno vrijeme provedeno u prometnoj mreži simulacijskog modela i trend smanjivanja ukupnog vremena putovanja prikazani su na slici 31, a ukupno vrijeme putovanja po smjerovima na slici 32.



Slika 31. Učinkovitost uporabe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na ukupno vrijeme putovanja u slučaju sa zagušenjem



Slika 32. Ukupno vrijeme putovanja po prometnim smjerovima u slučaju sa zagušenjem

Isto ispitivanje provedeno je i pri uvjetima normalnog opterećenja prometnica bez zagušenja (~3000 vozila) te su u tablicama 11, 12, 13 i 14 prikazani statistički pokazatelji za odnosni slučaj.

Tablica 11. Statistički pokazatelji za slučaj bez RG

Smjer	Broj vozila N	Vrijeme t [s] provedeno u mreži	t_{\min} [s]	t_{\max} [s]	t_{sr} [s]	σ_t [s]
1.	275	76219,00	220,56	325,58	254,06	38,28
2.	771	104088,00	261,44	410,40	346,96	48,48
3.	302	48121,00	112,88	196,00	160,40	33,80
4.	265	79810,00	209,00	416,84	266,04	77,48
5.	316	58091,00	167,42	213,02	193,64	19,42
6.	431	71077,00	184,96	274,84	236,92	36,52
7.	290	78370,00	115,88	381,20	261,24	95,00
8.	303	123944,00	319,80	497,54	413,14	62,54
9.	433	38389,00	86,48	173,18	127,96	30,72
Ukupno:	3386	678109,00				

Tablica 12. Statistički pokazatelji za slučaj s 10 % RG

Smjer	Broj vozila N	Vrijeme t [s] provedeno u mreži	t_{\min} [s]	t_{\max} [s]	t_{sr} [s]	σ_t [s]
1.	299	85560,00	235,36	446,82	285,20	80,24
2.	772	107426,00	246,82	424,24	358,08	60,16
3.	277	48214,00	115,18	191,46	160,72	27,18
4.	290	72821,00	207,62	278,02	242,74	26,62
5.	290	54971,00	113,32	226,06	183,24	41,52
6.	424	77448,00	210,56	301,78	258,16	30,76
7.	301	85720,00	185,72	342,22	285,74	54,58
8.	298	105034,00	240,28	478,88	350,12	79,96
9.	446	35211,00	64,28	168,90	117,38	36,58
Ukupno:	3397	672405,00				


Tablica 13. Statistički pokazatelji za slučaj s 25 % RG

Smjer	Broj vozila N	Vrijeme t [s] provedeno u mreži	t_{\min} [s]	t_{\max} [s]	t_{sr} [s]	σ_t [s]
1.	304	84908,00	247,96	424,80	283,02	69,70
2.	768	102737,00	233,88	396,34	342,46	59,76
3.	280	50715,00	151,00	186,42	169,06	14,56
4.	285	70853,00	215,50	256,58	236,18	15,46
5.	286	53443,00	113,14	241,56	178,14	43,06
6.	420	76006,00	209,34	298,60	253,36	31,74
7.	308	85677,00	179,58	366,62	285,60	74,96
8.	294	111082,00	235,22	451,02	370,28	72,80
9.	444	35567,00	65,22	165,70	118,56	35,14
Ukupno:	3389	670988,00				


Tablica 14. Statistički pokazatelji za slučaj s 50 % RG

Smjer	Broj vozila N	Vrijeme t [s] provedeno u mreži	t_{\min} [s]	t_{\max} [s]	t_{sr} [s]	σ_t [s]
1.	277	78408,00	219,06	303,64	261,36	36,10
2.	777	104709,00	259,46	411,82	349,04	50,52
3.	287	44638,00	122,58	199,90	148,80	30,64
4.	282	82290,00	208,92	442,66	274,30	86,08
5.	311	52190,00	147,42	200,46	173,96	17,94
6.	433	73596,00	184,64	290,58	245,32	40,92
7.	296	80865,00	115,56	364,70	269,54	93,18
8.	294	108766,00	302,40	457,30	362,56	56,82
9.	433	35489,00	98,96	133,84	118,30	14,94
Ukupno:	3390	660951,00				

Ukupno vrijeme putovanja, odnosno ukupno vrijeme provedeno u prometnoj mreži simulacijskog modela prikazano je na slici 33, a ukupno vrijeme putovanja po smjerovima na slici 34.



Slika 33. Učinkovitost uporabe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na ukupno vrijeme putovanja u slučaju bez zagušenja



Slika 34. Ukupno vrijeme putovanja po prometnim smjerovima u slučaju bez zagušenja


7.2.2. Prijedeni put

Uz vrijeme putovanja koje je prikazano u prethodnom potpoglavlju uspješnost predloženog modela može se prikazati i pomoću ukupnog prijeđenog puta. Ukupan prijeđeni put u metrima koji su vozila u simulacijskom modelu prešla u razdoblju trajanja simulacije (5400 s) prikazan je u tablici 15 za četiri različita scenarija u slučaju zagušenog prometnog toka.

Tablica 15. Pokazatelji uspješnosti u slučaju sa zagušenjem

Scenarij	Broj vozila <i>N</i>	Ukupni prijeđeni put <i>s</i> [m]
Bez RG	5959	14804116
10 % RG	6052	13866426
25 % RG	6087	13165188
50 % RG	6087	13108608

Na slici 35 grafički je prikazano u kojoj se mjeri razlikovao ukupni prijeđeni put ovisno o primijenjenom scenariju.




Slika 35. Učinkovitost uporabe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na prijeđeni put u slučaju sa zagušenjem

U tablici 16 prikazani su prijeđeni putovi za četiri predviđena scenarija u slučaju kad na prometnicama u simulacijskom modelu ne vlada zagušenje.

Tablica 16. Pokazatelji uspješnosti u slučaju bez zagušenja

Scenarij	Broj vozila N	Ukupni prijeđeni put s [m]
Bez RG	3386	8584562,28
10 % RG	3397	8521011,61
25 % RG	3389	8194632,91
50 % RG	3390	8104471,59

Slika 36. prikazuje ukupan prijeđeni put u metrima ovisno o primijenjenom scenariju.



Slika 36. Učinkovitost upotrebe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na prijeđeni put u slučaju bez zagušenja


7.2.3. Ukupni troškovi

Ukupne troškove putovanja čini niz različitih čimbenika kao što je to navedeno u potpoglavlju 6.3.2. Oni ovise npr. o količini utrošenog goriva, starosti i karakteristikama korištenih tipova vozila, kvaliteti prometnica i sl., ali i o troškovima upotrebe prometnica ili cestarini i cijeni parkiranja. Uzevši u obzir sedam različitih modela vozila koji su se koristili u ovom simulacijskom modelu i ostale prethodno opisane postavljene parametre ukupni troškovi ovisno o predviđenim scenarijima prikazani su u tablici 17 za slučaj zagušene prometne mreže simulacijskog modela. Svi prikazani iznosi izraženi su u kunama [kn].

Tablica 17. Pokazatelji uspješnosti u slučaju sa zagušenjem

Scenarij	Broj vozila N	Ukupan trošak C [kn]
Bez RG	5959	22256,66
10 % RG	6052	20398,98
25 % RG	6087	19208,34
50 % RG	6087	18751,34

Slika 37. grafički prikazuje razliku ukupnih troškova putovanja izraženu u kunama [kn] ovisno o scenariju za zagušeni prometni tok.




Slika 37. Učinkovitost upotrebe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na ukupan trošak u slučaju sa zagušenjem

Na isti su način kao i u prethodnom slučaju prikazani podaci za prometnu mrežu simulacijskog modela bez zagušenja (vidi tablicu 18).

Tablica 18. Pokazatelji uspješnosti u slučaju bez zagušenja

Scenarij	Broj vozila N	Ukupan trošak C [kn]
Bez RG	3386	12906,12
10 % RG	3397	12486,03
25 % RG	3389	11922,54
50 % RG	3390	11671,72

Na slici 38 prikazani su ukupni troškovi putovanja za slučaj prometne mreže simulacijskog modela bez zagušenja.



Slika 38. Učinkovitost upotrebe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na ukupan trošak u slučaju bez zagušenja

7.2.4. Emisija štetnih plinova

Emisija štetnih plinova ovisno o svojim čimbenicima može znatno varirati što pokazuju različita ispitivanja [156]. Vrsta goriva, temperatura i karakteristike svakog pojedinog vozila čine ovaj tip analize veoma složenim i kompleksnim pa se stoga primjenjuju različite metodologije i pristupi kako bi se čim kvalitetnije odredila obilježja ovoga negativnog učinka. Prema navodima američke Agencije za zaštitu okoliša (*Environmental Protection Agency*) [157] dvije se općenite metode mogu koristiti za izračunavanje emisije štetnih plinova: izračunavanje pomoću stopa emisije štetnih plinova vozila i izračunavanje pomoću potrošnje goriva. Prvi navedeni pristup je, za razliku od drugog tradicionalnog pristupa, više zastupljen u znanstvenim krugovima zbog razvijenih modela i programskih alata za učinkovitu procjenu stope emisije različitih tipova vozila (npr. MOVES, EMFAC, PHEM, VERSIT, COPERT).


Za procjenu emisije štetnih plinova primjenjuju se različite tehnike i metodologije [158]. U sklopu ovog istraživanja koristi se metoda koja se zasniva na kombinaciji mikroskopskog prometnog simulacijskog modela u VISSIM-u i MOVES (*Motor Vehicle Emission Simulator*) modela emisije koju su u svom radu predložili Senna et al. [159]. Model je prilagođen karakteristikama vozila na području RH prema dostupnim podacima i u skladu s podacima simulacijskog modela.

U tablici 19 prikazana je ukupna emisija NO₂ koju su sadržavali ispušni plinovi svih vozila simulacijskog modela za predviđena četiri scenarija u slučaju zagušenja i bez zagušenja prometne mreže.

Tablica 19. Ukupna emisija dušikovog dioksida NO₂

Scenarij	NO ₂ [mg] (zagušenje)	NO ₂ [mg] (bez zagušenja)
Bez RG	1761690	592335
10 % RG	1650105	587950
25 % RG	1566657	565430
50 % RG	1559924	559209

Razlika u vrijednostima između pojedinih scenarija grafički je prikazana na slici 39.




Slika 39. Ukupna emisija dušikovog dioksida NO₂

Na jednak je način prikazana ukupna emisija CO₂ u tablici 20. Podaci su izloženi na osnovi ukupne količine ispušnih plinova svih vozila simulacijskog modela za predviđena četiri scenarija u slučaju zagušenja i bez zagušenja prometne mreže.

Tablica 20. Ukupna emisija ugljičnog dioksida CO₂

Scenarij	CO ₂ [g] (zagušenje)	CO ₂ [g] (bez zagušenja)
Bez RG	1931527	1115993
10 % RG	1917228	1107732
25 % RG	1843792	1065302
50 % RG	1823506	1053581

Razlika u vrijednostima između pojedinih scenarija grafički je prikazana na slici 40.

**Slika 40.** Ukupna emisija ugljičnog dioksida CO₂

7.3. Diskusija rezultata

Pokazatelji uspješnosti koji su dobiveni kao rezultat provedenih simulacija potvrđuju početne pretpostavke da će se uvođenje naprednog sustava za upućivanje na raspoloživa parkirališna mjesta pozitivno odraziti na postojeća zagušenja u gradskim središtima. Analiza dobivenih pokazatelja ukazuje da se u slučaju sa zagušenim prometnim tokom ukupno vrijeme putovanja u prosjeku skraćuje 7,36 %, tj. u rasponu od 1,63 % do 13,09 % ovisno o analiziranom scenariju. Slično tome, ukupni prijeđeni put u prosjeku se smanjio za 8,85 %,

tj. u rasponu od 6,28 % do 11,42 %. Konačno, ukupni su se troškovi u prosjeku umanjili za 12,05 %, tj. u rasponu od 8,35 % do 15,75 %. U slučaju prometnog toka bez zagušenja ukupno se vrijeme putovanja ovisno o scenariju skraćuje u rasponu od 0,84 % do 2,53 %, ukupni prijeđeni put od 0,75 % do 5,60 %, a ukupni troškovi od 3,25 % do 9,56 %. Komparativnom analizom navedenih vrijednosti može se zaključiti da je sustav učinkovitiji u slučajevima zagušenja što je bilo i za očekivati jer su u drugom slučaju optimalni putovi puno kraći i vozila se kreću bez zastoja i gužvi, a samim time sva vozila brže ostvaruju svoje ciljeve neovisno o tome jesu li ili nisu opremljena naprednim sustavom za upućivanje na raspoloživa parkirališna mjesta.

Ukupno vrijeme putovanja, odnosno ukupno vrijeme provedeno u prometnoj mreži simulacijskog modela mijenjalo se ovisno o zastupljenosti naprednog sustava za upućivanje vozila na raspoloživa parkirališna mjesta što se jasno može vidjeti na slikama 31. i 33. Primjena naprednog sustava za upućivanje na raspoloživa parkirališna mjesta nije utjecala samo na vozila koja su brže, jednostavnije i uspješnije pronalazila raspoloživa parkirališna mjesta već i na vozila u tranzitu koja su brže stizala od ulaza do izlaza prometne mreže uslijed manje razine zagušenja. Vrijeme putovanja se na zagušenim smjerovima smanjivalo, a na smjerovima s manjim prometnim volumenom povećavalo zbog uporabe alternativnih ruta putovanja (slike 32 i 34), te se u prometnoj mreži stvorila svojevrsna ravnoteža. Sličan učinak može se prepoznati i na slikama 35. i 36. koje prikazuju u kojoj se mjeri umanjio ukupan prijeđeni put u simulacijskom modelu te na slikama 37. i 38. iz kojih se može vidjeti kako su se uštede na vremenu putovanja i prijeđenom putu odrazile na ukupne troškove.

Smanjenje ukupnog vremena putovanja, kraći ukupni prijeđeni put i manji troškovi putovanja utječu na smanjenje zagušenja u gradskim središtima te rezultiraju većim zadovoljstvom vozača. Indirektno oni utječu i na smanjenje potrošnje goriva, a time i na manju emisiju štetnih plinova, povećanje sigurnosti u prometu, smanjenje buke, stresa i troškova putovanja.

Za prikaz učinkovitosti naprednog sustava za upućivanje na raspoloživa parkirališna mjesta u smanjenju emisije štetnih plinova uzeta su dva reprezentata i to NO_2 i CO_2 . Ovisno o udjelu naprednog sustava za upućivanje na raspoloživa parkirališna mjesta u ukupnom broju vozila u simulacijskom modelu ukupna količina NO_2 i CO_2 se smanjivala kako je prikazano na slikama 39. i 40. Navedeno smanjenje je naglašenije u slučaju zagušenog prometnog toka dok je kod prometnog toka bez zagušenja ono znatno slabije istaknuto.

Svi prikazani pokazatelji uspješnosti i rezultati provedene analize potvrđuju opravdanost uvođenja naprednog sustava za upućivanje na raspoloživa parkirališna mjesta kao jednog od potencijalnih rješenja problema parkiranja i zagušenja u gradskim središtima.

8. ZAKLJUČAK

Inteligentni parkirni sustavi su složeni sustavi koji uključuju različite podsustave, a time u svoju implementaciju neizostavno moraju uključiti i stručnjake s različitih stručnih i znanstvenih područja. Problem parkiranja i parkirališta, te njegov utjecaj na razvijene sredine poznat je gotovo pedeset godina. Stoga je i očito zašto je i dalje predmet mnogih znanstvenih i stručnih diskusija i radova, a jednako tako i jedna od osnova za istraživanje provedeno u ovome radu.

Sustavi za upućivanje na raspoloživa parkirališna mjesta pokušavaju ponuditi odgovarajući odgovor na probleme izazvane parkiranjem, no to im zbog ograničenih uvjeta uspijeva tek u nekoliko segmenata ovog opsežnog problema. Na toj je činjenici i nastala ideja o primjeni novih tehnologija i kooperativnog pristupa, a sve kako bi se dio nedostataka takvih sustava uspio ublažiti ili u cijelosti riješiti. Istraženi su postojeći sustavi i njihova obilježja, ispitani su algoritmi i metode koje isti koriste u svojem djelovanju, te sve ostale potencijalne mogućnosti unaprjeđenja i povećanja učinkovitosti. Prepoznate su prednosti i nedostaci koje pojedini sustavi imaju u odnosu na druga rješenja i upravo se na temelju tih iskustava izgradio napredni model sustava za upućivanje na raspoloživa parkirališna mjesta opisan u ovom radu. Osnovna je ideja, koja se uslijed toga logički nametnula, da ponuđeno rješenje obuhvati sve raspoložive parkirališne kapacitete i upravlja njima pomoću novih tehnologija, prije svega na području komunikacije i modernih naprednih osjetila.

Vodeći nedostaci klasičnih pristupa koji se koriste u postojećim sustavima su nemogućnost upravljanja uličnim parkirališnim prostorima i nedovoljno kvalitetnim algoritmima za upućivanje na raspoloživa parkirališna mjesta. Uz navedeno, gotovo je nemoguće da isti sa sigurnošću garantiraju za ponuđeno parkirališno mjesto. Rezultat takvih sustava se stoga očituje u relativno visokom nezadovoljstvu korisnika i nedovoljno učinkovitom rješavanju problema jer dio vozila nastavlja kružiti u potrazi za raspoloživim parkirališnim mjestom uslijed loših i nepreciznih informacija koje su daleko od stvarnovremenskog režima rada. Kooperativni pristup nudi raspolaganje informacijama puno brže jer ih korisnici sustava dobivaju prema potrebi direktno bez nužnog kontakta s naprednim sustavom za informiranje. Vozila i osjetila u infrastrukturi, koja sada zapravo predstavljaju svojevrsna mikroročunala, sposobna su analizirati i obraditi dio informacija te ih međusobno prosljeđivati u svrhu boljeg upravljanja. Iz svega navedenog jasno je uslijed čega predloženi napredni model sustava koristi upravo kooperativan pristup, pogotovo s obzirom na

sinergijski učinak optimalnog izbora rute i odgovarajućeg raspoloživog parkirališnog mjesta.

Predviđeni rast proizvodnje vozila koja su opremljena sustavima s kooperativnim mogućnostima i očekivani razvoj svih telematičkih sustava u vozilu preduvjet su za ozbiljno razmatranje predloženog sustava kao potencijalnog rješenja problema zagušenja i parkiranja u gradskim središtima. Opsežna testiranja i najave proizvođača vozila i opreme idu u prilog tome i potvrđuju buduću ekspanziju ovakvih sustava. Stoga su i opravdani naponi koji se ulažu u istraživanja i ispitivanja njihovih učinaka i razine uspješnosti u različitim scenarijima, uvjetima i okruženjima.

Iskustva pokazuju da se vozači s većim iskustvom pri parkiranju ponašaju upravo onako kako bi to predlagao inteligentni transportni sustav jer koriste ustaljene rute i redoslijede pri traženju raspoloživih parkirališnih mjesta na osnovi niza prethodnih uspješnih i neuspješnih pokušaja. Inteligentna parkirna rješenja ovaj slučaj pokušavaju modelirati pomoću povijesnih podataka o parkiranju i razviti algoritme predikcije slobodnih parkirališnih mjesta ako ne postoje unaprijed predviđeni načini rezervacije i naplate parkiranja. Pružanjem odgovarajućih informacija vozačima, mijenjaju se polako njihove navike što također može dovesti do negativnog učinka jer ćemo oslobađanjem prometna jednog cestovnog segmenta potencijalno dovesti u opasnost neku drugu prometnu dionicu.

Bez obzira na sve prednosti koje donosi uvođenje sustava za upućivanje na raspoloživa parkirališna mjesta, još uvijek ostaje otvoreno pitanje odgovarajućeg rješenja za rezervaciju uličnih parkirališnih mjesta koje se može smatrati jednim od njihovih vodećih nedostataka. Postojeća rješenja su prema mišljenju autora neodgovarajuća, neučinkovita i neisplativa, te ne opravdavaju svoju primjenu u danim slučajevima.

Dobiveni rezultati u svim ispitanim slučajevima i scenarijima u ovome radu jasno ukazuju na učinkovitost sustava neovisno o tome radi li se samo o rasterećenju prometnog toka uslijed optimalnijeg iskorištavanja postojećih prometnih kapaciteta uporabom poboljšanih algoritama za upućivanje vozila i navigaciju ili se zbog raspoloživih informacija o slobodnim parkirališnim mjestima smanjuje nepotrebno kruženje. Izgrađenim dinamičkim simulacijskim modelom naprednog sustava za upućivanje vozila na raspoloživa parkirališna mjesta i njegovim ispitivanjem i ocjenjivanjem potvrđena je njegova učinkovitost kako u pogledu smanjivanja ukupnog vremena putovanja, tako i u pogledu smanjenja ukupnog prijednog puta, ukupnih troškova i ukupne količine utrošenog goriva, a time i emisije štetnih plinova. Smanjenje zagušenja, koje je jedno od glavnih pokazatelja uspješnosti, utjecat će i na opću sigurnost u prometu te rezultirati manjim brojem prometnih nezgoda koje su direktno ili indirektno uzrokovane parkiranjem.

Rezultati analize i evaluacije upravo pokazuju u kojoj mjeri kooperativni sustavi učinkovito djeluju na problem kruženja i traženja raspoloživog parkirališnog mjesta u odnosu na klasičan pristup, što je posebno istaknuto u slučaju sa zagušenjem. Ovi sustavi fuzijom poznatih povijesnih podataka i prikupljenih osjetilnih informacija odlučuju koja su od ponuđenih rješenja optimalna te se zatim predlažu zainteresiranim korisnicima. Iz svega navedenog je razvidno da predloženi model sustava za upućivanje na raspoloživa parkirališna mjesta s kooperativnim pristupom znatno unaprijeđuje i poboljšava karakteristike postojećih sustava, posebno u segmentu uličnog parkiranja, čime su u cijelosti potvrđene glavna i pomoćne hipoteze postavljene na početku istraživanja.

Ispravnosti glavne i pomoćnih teza doktorskog rada predstavljenih u potpoglavlju 1.2. dokazane su u poglavlju 7. provedenim simulacijama uporabe naprednog sustava za upućivanje vozila na raspoloživa parkirališna mjesta u slučajevima s i bez zagušenja. Pokazatelji uspješnosti u potpoglavljima 7.2.1., 7.2.2., 7.2.3. i 7.2.4. jasno pokazuju smanjenje negativnih učinaka poput zagušenja i smanjene sigurnosti vozača i putnika (*PH1* i *PH2*), koje uzrokuje kruženje u potrazi za slobodnim parkirališnim mjestom čime se implicitno dokazuje temeljna znanstvena hipoteza. U potpoglavlju 7.2.1. eksplicitno je prikazano smanjenje vremena putovanja (*PH3*).

S obzirom na sve prethodno navedeno, proizlazi i znanstveni doprinos ovoga rada koji se očituje u sljedećem:

- predložen je, ispitan i verificiran napredni model sustava za upućivanje na raspoloživa parkirališna mjesta upotrebom kooperativnog pristupa koji uključuje niz pogodnosti prije svega omogućenih inteligentnim osjetilima i komunikacijskim tehnologijama
- proširene su i poboljšane informacijsko-komunikacijske karakteristike telematičkih sustava u vozilu
- unaprijeđena je algoritamska struktura za dinamičku korekciju prometnih pravaca u realnom vremenu u funkciji učinkovitijeg upućivanja vozila
- stvoreni su preduvjeti za razvoj i realizaciju strategija budućih PGI sustava.

Rezultati istraživanja nastali u okviru ovoga rada imaju namjeru proširiti spoznaje o problematici parkiranja i fenomenu kruženja u potrazi za slobodnim parkirališnim mjestom. Oni predstavljaju opravdanje za pokretanje novih istraživanja koja bi se provodila za stvarna gradska središta i uz stvarne podatke i uvjete na gradskim prometnicama. Buduća bi istraživanja mogla obuhvatiti i detaljnije opisati utjecaj ponašanja vozača i njihovih karakteristika na učinkovitost sustava, uključiti i druge čimbenike poput cijene parkiranja,

režima parkiranja i ograničene dužine parkiranja, te kombinirati utjecaj sustava za upućivanje na raspoloživa parkirališna mjesta te druge strategije u sprječavanju zagušenja.

Predloženi napredni model sustava upućivanja na raspoloživa parkirališna mjesta također bi trebao potaknuti stvaranje novih strategija i politika parkiranja, koje bi u zajedničkom djelovanju sa sustavom smanjile troškove gradskim vlastima, poduzetnicima i tvrtkama, razvojnim inženjerima i korisnicima te unaprijedile kvalitetu usluge parkiranja i ostvarile značajnu dobrobit za zajednicu u cjelini. Njime bi se trebali ubrzati procesi razvoja budućih sustava koji koriste sličnu tehnologiju i pružiti odgovarajuće informacije arhitektima, dizajnerima i planerima o načinima za zadovoljavanje zahtjeva parkiranja čime bi postao čvrsta podrška inteligentnom razvoju gradova.

Utjecaj predloženog sustava očituje se ne samo na smanjenju ekoloških onečišćenja, već i na unaprjeđenje putovanja, transporta i prometa u cjelini. Primjena predloženog inteligentnog sustava u gradovima ostvarit će preduvjete za kvalitetnije iskorištavanje prostora i stvaranje privlačnije i ugodnije urbane okoline.

Rezultati istraživanja mogli bi također potaknuti pokretanje većeg broja tehnoloških projekata vezanih za unaprjeđenje strategija parkiranja u gradskim središtima.

To je od posebnog interesa u turističkim destinacijama u Republici Hrvatskoj, gdje postoje dva temeljna elementa koja upućuju na primjenu naprednih ITS rješenja:

- a) ograničene prostorne mogućnosti za rješavanje navedenih problema građenjem novih parkirališnih površina (*build only* pristup),
- b) velika disproporcija prometne potražnje u i izvanturističke sezone.

Ovo su dva temeljna razloga za primjenu inteligentnih sustava i predloženih naprednih tehnologija u rješavanju prometnih problema u gradovima.

POPIS KRATICA I AKRONIMA

ABS	–	<i>Anti-lock braking system</i>
ADAS	–	<i>Advanced Driver-Assistance Systems</i>
ALI	–	<i>Autofahrer Leit und Informationssystem</i>
ASR	–	<i>Antriebsschlupfregelung</i>
ASTM	–	<i>American Society for Testing and Materials</i>
ATDM	–	<i>Advanced Transportation and Demand Management</i>
ATIS	–	<i>Advanced traveler information systems</i>
AU	–	<i>Application unit</i>
AVL	–	<i>Automatic Vehicle Location</i>
C-ITS	–	<i>Cooperative Intelligent Transportation Systems</i>
C2C	–	<i>Car-to-Car</i>
C2I	–	<i>Car-to-Infrastructure</i>
C2X	–	<i>Car-to-Everything (C2C & C2I)</i>
CALM	–	<i>Communications access for land mobiles</i>
CARIN	–	<i>CAR Information and Navigation</i>
CDF	–	<i>Cumulative distribution function</i>
CDMA2000	–	<i>Code Division Multiple Access 2000</i>
CEN	–	<i>Comité Européen de Normalisation (European Committee for Standardization)</i>
CENELEC	–	<i>Comité Européen de Normalisation Électrotechnique (European Committee for Electrotechnical Standardization)</i>
CF	–	<i>Commonality factor</i>
CLU	–	<i>Cooperative Learning Unit</i>
CNL	–	<i>Cross-Nested Logit</i>
CORS	–	<i>Continuously Operating Reference Stations</i>
CS	–	<i>Central Sub-system</i>
CSG	–	<i>Choice set generation</i>
CSMA	–	<i>Carrier sense multiple access</i>
CW	–	<i>Continuous Wave</i>

DAB	–	<i>Digital Audio Broadcast</i>
DCC	–	<i>Distributed congestion control</i>
DMS	–	<i>Dynamic message sign</i>
DoT	–	<i>Department of Transport</i>
DSRC	–	<i>Dedicated short-range communication</i>
DTA	–	<i>Dynamic Traffic Assignment</i>
DUE	–	<i>Deterministic user equilibrium</i>
EBA	–	<i>Elimination by Aspects</i>
EGNOS	–	<i>European Geostationary Navigation Overlay Service</i>
EPA	–	<i>European Parking Association</i>
ESP	–	<i>Electronical stability program</i>
ETSI	–	<i>European Telecommunications Standards Institute</i>
FAA	–	<i>Federal Aviation Administration</i>
FCC	–	<i>Federal Communications Commission</i>
FIA	–	<i>Fédération Internationale de l'Automobile</i>
FOS	–	<i>Fiber optic shutter</i>
GAGAN	–	<i>GPS and GEO Augmented Navigation</i>
GBAS	–	<i>Ground Based Augmentation Systems</i>
GEV	–	<i>Generalized Extreme Value</i>
GIS	–	<i>Geografski informacijski sustavi</i>
GLONASS	–	<i>GLObalnaya NAVigatsionnaya Sputnikovaya Sistema</i>
GNSS	–	<i>Globalni navigacijski satelitski sustavi</i>
GPS	–	<i>Global Positioning System</i>
GPRS	–	<i>General Packet Radio Service</i>
GRAS	–	<i>Ground-based Regional Augmentation System</i>
GW	–	<i>Gateway</i>
HAR	–	<i>Highway Advisory Radio</i>
HSDPA	–	<i>High-Speed Downlink Packet Access</i>
HSUPA	–	<i>High-Speed Uplink Packet Access</i>
IAP	–	<i>Implicit Availability/Perception</i>

i.i.d.	–	<i>Independent and identically distributed</i>
ICSI	–	<i>Intelligent Cooperative Sensing for Improved traffic efficiency</i>
IIA	–	<i>Independence of irrelevant alternatives</i>
IEEE	–	<i>Institute of Electrical and Electronics Engineers</i>
ILD	–	<i>Inductive loop detectors</i>
IoT	–	<i>Internet of Things</i>
IPI	–	<i>International Parking Institute</i>
IRNSS	–	<i>Indian Regional Navigation Satellite System</i>
ISM	–	<i>Instrumentation, Scientific and Medical</i>
ISO	–	<i>International Organization for Standardization</i>
ITS	–	<i>Intelligent Transportation Systems</i>
LAAS	–	<i>Local Area Augmentation System</i>
LED	–	<i>Light emitting diode</i>
LEED	–	<i>Leadership in Energy and Environmental Design</i>
LTE	–	<i>Long-term evolution</i>
M2M	–	<i>Machine to machine</i>
MAC	–	<i>Medium Access Layer</i>
MANET	–	<i>Mobile ad hoc network</i>
MEMS	–	<i>Microelectromechanical systems</i>
MNL	–	<i>Multinomial Logit</i>
MOVES	–	<i>Motor Vehicle Emission Simulator</i>
MR	–	<i>Mobile Reservation</i>
MSA	–	<i>Method of Successive Averages</i>
MSAS	–	<i>Multi-Functional Satellite Augmentation System</i>
NAVSTAR	–	<i>NAVigation Satellite Timing And Ranging system</i>
NEMS	–	<i>Nanoelectromechanical systems</i>
NL	–	<i>Nested Logit</i>
O	–	<i>Odredište</i>
OBU	–	<i>On-board unit</i>
OD	–	<i>Origin-destination</i>

OSI	–	<i>Open Systems Interconnection</i>
P+R (P&R)	–	<i>Park & Ride</i>
PDA	–	<i>Personal Data Assistants</i>
PGIS	–	<i>Parking guidance and information system</i>
PGS	–	<i>Parking Guidance System</i>
PND	–	<i>Personal Navigation Devices</i>
PS	–	<i>Personal Sub-system</i>
PSL	–	<i>Path-Size Logit</i>
PTV	–	<i>Planungsbüro Transport und Verkehr</i>
QoS	–	<i>Quality of service</i>
QZSS	–	<i>Quasi-Zenith Satellite System</i>
r. p. m.	–	<i>Raspoloživa parkirališna mjesta</i>
RDS	–	<i>Radio data System</i>
RG	–	<i>Route guidance</i>
ROI	–	<i>Region of interest</i>
RS	–	<i>Road Sub-system</i>
RSU	–	<i>Road Side Units</i>
SBAS	–	<i>Satellite Based Augmentation Systems</i>
SUE	–	<i>Stochastic user equilibrium</i>
TC	–	<i>Telecommunications Committee</i>
TMC	–	<i>Traffic Message Channel</i>
UMTS	–	<i>Universal Mobile Telecommunications System</i>
V-D	–	<i>Volume-delay</i>
V2V	–	<i>Vehicle-to-Vehicle</i>
V2I	–	<i>Vehicle-to-Infrastructure</i>
V2X	–	<i>Vehicle-to-Everything (V2V & V2I)</i>
VANET	–	<i>Vehicular ad hoc network</i>
VICS	–	<i>Vehicle Information Communication System</i>
VIP	–	<i>Video image processors</i>
VISSIM	–	<i>Verkehr In Städten – SIMulationsmodell</i>

VMS	–	<i>Variable message sign</i>
VS	–	<i>Vehicle Sub-system</i>
WAAS	–	<i>Wide Area Augmentation System</i>
WANET	–	<i>Wireless ad hoc network</i>
WAVE	–	<i>Wireless access in vehicular environment</i>
WiMAX	–	<i>Worldwide Interoperability for Microwave Access</i>
WSN	–	<i>Wireless Sensor Network</i>

POPIS OZNAKA I SIMBOLA

a	–	prometna dionica
a_r	–	indeks ruba
A	–	akumulacija parkiranja
A_0	–	akumulacija parkiranja na početku razdoblja trajanja atraktivnosti
A_{in}^*	–	latentna raspoloživost alternative i
A_j	–	broj jednovremeno parkiranih vozila u j -tom vremenskom presjeku
A_{max}	–	maksimalna akumulacija parkiranja u razdoblju trajanja atraktivnosti
C	–	opći trošak putovanja
C_f	–	zbroj troškova svih prometnih dionica koje čine jedan rub
C_j	–	opći troškovi puta ili rute j
C_{mn}	–	skup izbora mogućih putova za svaki n u M gnijezda
C_n	–	skup izbora mogućih putova za svaki n
C_{n2}	–	dodatni trošak prometne dionice (nadoplata 2) koji nije opterećen čimbenikom γ
$C_{Parking}$	–	cijena parkiranja u zoni
C_R	–	opći trošak rute R
C_{voz}	–	opći troškovi najjeftinije rute od trenutne pozicije vozila
CF	–	čimbenik istovjetnosti
D_{odr}	–	zračna udaljenost između centra odredišne zone i parkirališnog mjesta
f_s	–	raspoloživost slobodnih parkirališnih mjesta
F	–	matrica težinskih koeficijenata J_n puta M
g	–	varijanca standardne Gumbelove varijable
G	–	skup svih mogućih skupova izbora, odnosno skup svih nepraznih podskupova od M
h_{ink}	–	kriterijska funkcija koja se odnosi na alternativu i

i_r	–	indeks ruba
$I_{c_{mn}}$	–	maksimalna korisnost svih alternativa u gnijezdu
J	–	broj alternativa u glavnom skupu izbora M
k	–	obrt ili izmjena parkiranja
k_{atr}	–	stupanj atraktivnosti
k_i	–	broj ostvarenih parkiranja na i -tom mjestu za parkiranje u razdoblju Δt
k_{isk}	–	koeficijent iskorištenja
$K_{isk_{pros}}$	–	prosječan koeficijent iskorištenja ili indeks parkiranja
k_o	–	parametar osjetljivosti modela
k_s	–	indeks scenarija
k_{sred}	–	srednji broj izmjena parkiranja u promatranom vremenu Δt po jednom parkirališnom mjestu
k_{tv}	–	indeks tipa vozila
K	–	kapacitet (propusna moć) prometnice u razdoblju od jednog sata
K_{ei}	–	indeks evaluacijskog intervala u razdoblju simulacije
K_i	–	skup ograničenja koji se odnosi na alternativu i
l_a	–	dužina prometne dionice a
L_i	–	dužina puta ili rute i
L_j	–	dužina puta ili rute j
L_{ij}	–	udaljenost putova ili ruta i i j
L_p	–	udaljenost za pješaćenje
M	–	ukupan broj parkirališnih mjesta
n	–	indeks iteracije dodjeljivanja
N	–	korisnički određena vrijednost
N_{an}	–	$\sum_{j \in C_n} \delta_{aj}$ za stvarne prometne dionice

$P(i)$	–	vjerojatnost da putnik koristi put i
$P_n(i)$	–	vjerojatnost da putnik n odabere put i
$P(i/C_n)$	–	vjerojatnost izbora alternative i u skupu C_n
$p(R_j)$	–	vjerojatnost odabira puta j
PS_{in}	–	veličina puta i za osobu n
r	–	rub koji pripada ruti R
R	–	ruta
s	–	čimbenik određen geometrijom prometnih dionica
t_1	–	vrijeme dolaska na parkirališno mjesto
$(t_1)_{ij}$	–	vrijeme dolaska j -tog vozila na i -to mjesto za parkiranje
t_2	–	vrijeme napuštanja parkirališnog mjesta
t_{f1}	–	vrijeme odašiljanja
t_{f2}	–	vrijeme prijema
t_{\max}	–	maksimalno vrijeme putovanja
t_{\min}	–	minimalno vrijeme putovanja
t_{sr}	–	srednje vrijeme putovanja
$(t_2)_{ij}$	–	vrijeme odlaska j -tog vozila sa i -tog mjesta za parkiranje
T	–	neodređeni vremenski interval
\mathbf{T}	–	donje trokutasta matrica M puta M nepoznatih parametara
T_0	–	vrijeme putovanja slobodnim tokom
$T_{a_r}^{n,K}$	–	očekivano vrijeme putovanja na rubu a za razdoblje k u iteraciji n
$T_i^{n,K}$	–	očekivano vrijeme putovanja na rubu i za razdoblje k u iteraciji n
$TO_{a_r}^{n,K}$	–	izmjereno vrijeme putovanja na rubu a za razdoblje k u iteraciji n
$TO_i^{n,K}$	–	izmjereno vrijeme putovanja na rubu i za razdoblje k u iteraciji n
T_c	–	zagušenje vremena putovanja na promatranoj prometnoj dionici

\mathbf{U}	–	vektor redak J_n korisnosti
U_j	–	korisnost puta j
V	–	prometni volumen u periodu od jednog sata
V_{in}	–	sustavna korisnost alternative i za n putnika
\mathbf{X}	–	matrica nezavisnih varijabli J_n puta K
Z	–	privlačnost karakteristika zone
Y_{ink}	–	k -ta varijabla u odnosu na raspoloživost alternative i za osobu n
α	–	čimbenik ponašanja vozača
α_{k_{tv}, k_s}	–	koeficijent funkcije korisnosti
α_{mi}	–	uključena težina alternative i u "gnijezdu" m
α_{pt}	–	parametar prometnog toka
α_z	–	parametar zaglađivanja
β	–	čimbenik ponašanja vozača
$\boldsymbol{\beta}$	–	vektor stupac K nepoznatih parametara
β_{k_{tv}, k_s}	–	koeficijent funkcije korisnosti
β_{pt}	–	parametar prometnog toka
β_0	–	kalibracijski koeficijent
γ	–	čimbenik ponašanja vozača
γ	–	kalibracijski koeficijent
γ_{bl}	–	koeficijent binarnog Logita
γ_{k_{tv}, k_s}	–	koeficijent funkcije korisnosti
δ_{aj}	–	"dummy" varijabla
δ_{k_{tv}, k_s}	–	koeficijent funkcije korisnosti
$\varepsilon_{k_{tv}, k_s}$	–	koeficijent funkcije korisnosti
$\boldsymbol{\zeta}$	–	vektor stupac M i.i.d. standardnih normalnih varijabli koje predstavljaju nepromatrane čimbenike

μ	–	parametar skaliranja
$\mu_n(i)$	–	raspoloživost puta i
$\bar{\mu}_n(i)$	–	očekivanje slučajne varijable $\mu_n(i)$
\mathbf{v}	–	vektor redak J_n i.i.d. Gumbelovih varijabli s parametrom skaliranja μ
v_{ink}	–	slučajni prag sa središtem u nuli
σ_t	–	standardna devijacija
Δf	–	razlika frekvencija
Δt	–	promatrani vremenski interval
Δt_p	–	trajanje parkiranja
θ	–	koeficijent korisnosti ili parametar brzine
Γ_i	–	skup dionica puta i
τ	–	srednje trajanje parkiranja na M parkirališnih mjesta

POPIS SLIKA

Slika 1.	Povećanje broja putničkih vozila na 1000 stanovnika 1990.-2004. [1]	1
Slika 2.	Rješenje telekomunikacijskog operatora u talijanskom gradu Pisi	30
Slika 3.	Prikaz mogućnosti rješenja za upućivanje na parkiranje pod nazivom <i>Fastprk</i>	30
Slika 4.	Koncept pametnog svijeta prema vizijama razvojnog tima poduzeća <i>Libelium</i>	32
Slika 5.	Rezultati istraživanja Međunarodnog instituta za parkiranje	34
Slika 6.	Prikaz trendova koji imaju najveći utjecaj na parkirališnu industriju [113]	36
Slika 7.	Prikaz trendova koji imaju najveći potencijal za poboljšanje održivosti [113]	36
Slika 8.	Magnetska osjetila (© nwavetec i libelium)	42
Slika 9.	Ultrazvučno osjetilo (© parksol)	44
Slika 10.	Navigacijski sustav tvrtke Navigon na priključnim mobilnim uređajima	48
Slika 11.	VMS u Rijeci	51
Slika 12.	Princip rada RDS-TMC	53
Slika 13.	Navigacijski sustav u Audi vozilima	56
Slika 14.	C-ITS sustav (Copyright © 2009 - 2012 European Business Press SA)	61
Slika 15.	Odnosi između normativnih tijela [123]	67
Slika 16.	Komponente sustava	70
Slika 17.	Logička ICSI arhitektura	72
Slika 18.	Domenski ICSI model	73
Slika 19.	Funkcionalni ICSI model	75
Slika 20.	ICSI komunikacijski model	77
Slika 21.	ICSI informacijski model	78
Slika 22.	Primjeri rutiranja	90
Slika 23.	Tipovi vozila u simulacijskom modelu	102
Slika 24.	OD matrica	105
Slika 25.	Primjer lanaca putovanja	105
Slika 26.	Princip dinamičkog dodjeljivanja [155]	106
Slika 27.	Klasični model putovanja, traženja raspoloživog parkirališnog mjesto i parkiranja	108
Slika 28.	Napredni model putovanja, traženja raspoloživog parkirališnog mjesto i parkiranja s kooperativnim pristupom	111
Slika 29.	Kooperativno djelovanje RSU, OBU i ATIS-a	112
Slika 30.	Primjeri dinamičkog odlučivanja o rutama vozila	118
Slika 31.	Učinkovitost upotrebe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na ukupno vrijeme putovanja u slučaju sa zagušenjem	125
Slika 32.	Ukupno vrijeme putovanja po prometnim smjerovima u slučaju sa zagušenjem	125

Slika 33.	Učinkovitost upotrebe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na ukupno vrijeme putovanja u slučaju bez zagušenja.....	128
Slika 34.	Ukupno vrijeme putovanja po prometnim smjerovima u slučaju bez zagušenja.....	128
Slika 35.	Učinkovitost upotrebe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na prijeđeni put u slučaju sa zagušenjem.....	129
Slika 36.	Učinkovitost upotrebe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na prijeđeni put u slučaju bez zagušenja.....	130
Slika 37.	Učinkovitost upotrebe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na ukupan trošak u slučaju sa zagušenjem.....	131
Slika 38.	Učinkovitost upotrebe sustava za upućivanje vozila na raspoloživa parkirališna mjesta u odnosu na ukupan trošak u slučaju bez zagušenja.....	132
Slika 39.	Ukupna emisija dušikovog dioksida NO ₂	133
Slika 40.	Ukupna emisija ugljičnog dioksida CO ₂	134

POPIS TABLICA

Tablica 1.	10 prometno najzagašenijih gradova u Europi u 2013. godini [3]	2
Tablica 2.	Usporedba cijena uličnog i izvanuličnog parkiranja* [20]	4
Tablica 3.	Broj parkirališnih mjesta u odnosu na veličinu grada.....	18
Tablica 4.	Sadržaj koji ATIS mogu prikazivati.....	40
Tablica 5.	GNSS klasifikacija.....	47
Tablica 6.	Usporedba MANET i VANET parametara [002]	59
Tablica 7.	Statistički pokazatelji za slučaj bez RG	123
Tablica 8.	Statistički pokazatelji za slučaj s 10 % RG	123
Tablica 9.	Statistički pokazatelji za slučaj s 25 % RG	124
Tablica 10.	Statistički pokazatelji za slučaj s 50 % RG	124
Tablica 11.	Statistički pokazatelji za slučaj bez RG	126
Tablica 12.	Statistički pokazatelji za slučaj s 10 % RG	126
Tablica 13.	Statistički pokazatelji za slučaj s 25 % RG	127
Tablica 14.	Statistički pokazatelji za slučaj s 50 % RG	127
Tablica 15.	Pokazatelji uspješnosti u slučaju sa zagušenjem	129
Tablica 16.	Pokazatelji uspješnosti u slučaju bez zagušenja	130
Tablica 17.	Pokazatelji uspješnosti u slučaju sa zagušenjem	131
Tablica 18.	Pokazatelji uspješnosti u slučaju bez zagušenja	131
Tablica 19.	Ukupna emisija dušikovog dioksida NO ₂	133
Tablica 20.	Ukupna emisija ugljikovog dioksida CO ₂	134

Bibliografija

- [1] Eurostat: "Are we moving in the right direction", European Environment Agency, Statistical yearbook on candidate countries, Office for Official Publications, 2003.
- [2] Shoup, D. C.: "Free Parking or Free Markets", *Access Magazine*, Vol. 38, 2011., str. 28.
- [3] TomTom European Traffic Indeks, TomTom International BV, 2014.
- [4] Mercuri, R., Bauen, A., Hart, D.: "Options for refuelling hydrogen fuel cell vehicles in Italy", *Journal of Power Sources*, Vol. 106, 2002., str. 353–363.
- [5] IBM Global Parking Survey: Drivers Share Worldwide Parking Woes, IBM, New York, 2011.
- [6] Parkplatznotstand und Ordnungswidrigkeiten (<http://focus.msn.de/F/FT/FTB/FTB113/ftb113.htm>), 2004.
- [7] White, P. S.: "No vacancy: Park slope's parking problem", *Transportation alternatives*, 2007.
- [8] Box, P. C.: "Questionable Concepts in Neotraditional Subdivision Design", *Transportation Research Circular*, No 501, Transportation Research Board, Washington, 2000.
- [9] European Commission Press Release, IP/13/236, Brisel, 19. ožujak 2013.
- [10] European Commission, Better information for safer EU roads – frequently asked questions, MEMO/13/436, Brisel, 15. svibanj 2013.
- [11] Marsden, G.: "The evidence base for parking policies – a review", *Transport policy*, Issue 13, 2006., str. 447-457.
- [12] Schrank, D., Lomax, T., Eisele, B.: "TTI's 2011 Urban Mobility Report", *Technical report*, Texas Transportation Institute, Texas A&M University College Station, 2011.
- [13] Shoup, D. C.: "Cruising for parking", *Transport Policy*, Vol. 13, 2006., str. 479–486.
- [14] K. Button: "The political economy of parking charges in||first and||second-best world", *Transport Policy*, Vol. 13, 2006., str. 470-478.
- [15] Axhausen, K. W.: "Ein ereignisorientierte Simulation von Aktivitätenketten zur Parkstandswahl", *Schriftenreihe des Instituts für Verkehrswesen*, Vol. 40, Universität (TH) Karlsruhe, Karlsruhe, 1989.
- [16] Axhausen, K.W.: "Ortskenntnis und Parkplatzwahlverhalten", report to the Deutsche Forschungsgemeinschaft, Institut für Verkehrswesen, Universität (TH) Karlsruhe, Karlsruhe, 1989.
- [17] Lorenz, K.: "Interim report on localised parking behaviour", Report from DRIVE project V1017 *Changes in Driver Behaviour due to the Introduction of RTI Systems*, Technische Universität Berlin, 1990.
- [18] Jones, P. M.: "Traffic regulation in urban areas: the public view point", *Working Paper*, 444, Transport Studies Unit, Oxford University, 1989.

- [19] Polak, J. W., Axhausen, K. W.: "The choice of mode and parking type in Birmingham: initial model estimation results", *Working Paper*, 522, Transport Studies Unit, Oxford University, 1990.
- [20] Shoup, D. C.: "The Ideal Source of Local Public Revenue", *Regional Science and Urban Economics*, Vol. 34 (6), 2004., str. 753-784.
- [21] Kodransky, M., Hermann, G.: "Europe's Parking U-Turn: From Accommodation to Regulation", Institute for Transportation and Development Policy, New York, 2011.
- [22] Brčić, D., Anžek, M., Matoš, S., Šćukanec, A.: "Telematički sustavi upućivanja na parkiranje u stvarnom vremenu s osvrtom na grad Zagreb", Znanstveni skup: Prometna problematika grada Zagreba, Zagreb, 2006., str. 49-57.
- [23] Mimbela, L. E. Y., Klein, L. A.: "Summary of vehicle detection and surveillance technologies used in intelligent transportation systems", Federal Highway Administration, Intelligent Transportation Systems Joint Program Office, Washington, DC, US, 2000.
- [24] Lee, S., Yoon, D., Ghosh, A.: "Intelligent Parking Lot Application Using Wireless Sensor Networks", International Symposium on Collaborative Technologies and Systems, 2008., str. 48-57.
- [25] Zhou, F., Li, Q.: "Parking Guidance System Based on ZigBee and Geomagnetic Sensor Technology", Distributed Computing and Applications to Business, Engineering and Science, 2014., str. 268-271.
- [26] Boda, V. K., Nasipuri, A., Howitt, I.: "Design Considerations for a Wireless Sensor Network for Locating Parking Spaces", IEEE SoutheastCon, 2007., str. 698-703.
- [27] Atmadja, W., Yosafat, J., Setiawan, R. A., Irendy, I. I.: "Parking guidance system based on real time operating system", *Industrial Automation, Information and Communications Technology*, 2014., str. 5-8,
- [28] Idris, M. Y. I., Tamil, E. M., Noor, N. M., Razak, Z., Fong, K. W.: "Parking Guidance System Utilizing Wireless Sensor Network and Ultrasonic Sensor", *Information Technology Journal*, 8(2), 2009., str. 138-146,
- [29] Suhr, J. K., Jung, H. G.: "Sensor Fusion-Based Vacant Parking Slot Detection and Tracking", *IEEE Transactions on Intelligent Transportation Systems*, Vol. 15 (1), 2014., str. 21-36.
- [30] Geng, Y., Cassandras, G. C.: "A new 'Smart Parking' System Infrastructure and Implementation", *Euro Working Group on Transportation*, International Scientific Conference, Paris, 2012.
- [31] Sykes, P., De Jong Grontmij, F., Bradley, R., Jennings, G., McDonnell, G.: "Planning urban car park provision using microsimulation", *Traffic, Engineering and Control*, Vol. 51 (3), 2010., str. 103-107.
- [32] Gallo, M., D'Acerno, L., Montella, B.: "A multilayer model to simulate cruising for parking in urban areas", *Transport policy*, Vol. 18, 2011., str. 735 - 744.
- [33] Arnott, R., Rave, T., Schöb, R.: "Alleviating urban traffic congestion", MIT press, Cambridge, USA, 2005.

- [34] "Traffic Congestion and Reliability: Trends and Advanced Strategies for Congestion Mitigation", *final report*, Cambridge Systematics, 2005.
- [35] New York Metropolitan Transportation Council: "Canal Area Transportation Study (CATS) ", Final Report for Public Review, 2010.
- [36] Weinberger, R., Kaehny, J., Rufo, M.: "U.S. Parking Policies: An Overview of Management Strategies", Institute for Transportation & Development Policy, USA, 2010.
- [37] Marsden, G.: "The Evidence Base for Parking Policy – A Review", *Transport Policy*, Vol. 13, 2006., str. 447-457.
- [38] Axhausen, K. W., Polak J. W., Boltze, M., Puzicha, J.: "Effectiveness of the parking guidance information system in Frankfurt am Main", *Traffic Engineering and Control*, Vol. 35 (5), 1994., str. 304-309.
- [39] Obdeijn, C.: "Modelling parking guidance systems in S-Paramics", magistarski rad, 2011.
- [40] Waterson, B. J., Chatterjee, K., Hounsell, N. B.: "Simulating the effectiveness of parking guidance systems", Presented at the 41st annual conference of the Operational Research Society, Edinburgh, UK, 1999.
- [41] Polak, J. W., Hilton, I. C., Axhausen, K. W., Young, W.: "Parking guidance and information systems: performance and capability", *Traffic Engineering and Control*, Vol. 31 (10), 1990., str. 519-524.
- [42] Mouftah, H. T., Khanafer, M., Guennoun, M.: "Wireless Sensor Network Architectures for Intelligent Vehicular Systems", Symposium International for Telecommunication Techniques, 2010.
- [43] Jeffrey, J., Patil, R. G., Narahari, S. K. K., Didagi, Y., Bapat, J., Dias, D.: "Smart parking system using wireless sensor networks", 6th International Conference on Sensor Technologies and Applications, 2012., str. 306-311.
- [44] Patil, M., Bhonge, V. N.: "Wireless Sensor Network and RFID for Smart Parking System", *International Journal of Emerging Technology and Advanced Engineering*, Vol. 3 (4), 2013., str. 188-192.
- [45] Ji, Z., Ganchev, I., O'Droma, M., Zhao, L., Zhang, X.: "A Cloud-Based Car Parking Middleware for IoT-Based Smart Cities: Design and Implementation", *Sensors*, Vol. 14, 2014.
- [46] Zanella, A., Bui, N., Castellani, A., Vangelista, L., Zorzi, M.: "Internet of Things for Smart Cities", *Internet of Things Journal*, 2014.
- [47] Arnott, R., De Palma, A., Lindsey, R.: "Does providing information to drivers reduce traffic congestion?", *Transportation Research Part A: General*, Vol. 25 (5), 1991., str. 309-318.
- [48] Mei, Z., Tian, Y.: "Optimized combination model and algorithm of parking guidance information configuration", *EURASIP Journal on Wireless Communications and Networking*, 2011., str. 1-9.
- [49] Martens, K., Benenson, I., Levy, N.: "The Dilemma of On-Street Parking Policy: Exploring Cruising for Parking Using an Agent-Based Model", *Geospatial Analysis and*

- Modelling of Urban Structure and Dynamics, *GeoJournal Library*, Vol. 99, Springer Science Business Media B.V., 2010, str. 121-138
- [50] Cassady, C. R., Kobza, J. E.: "A probabilistic approach to evaluate strategies for selecting a parking space", *Transportation Science*, Vol. 32 (1), 1998., str. 30-42.
- [51] Rhodes, C., Blewitt, W., Sharp, C., Ushaw, G., Morgan, G.: "Smart Routing: A Novel Application of Collaborative Path-finding to Smart Parking Systems", 16th Conference on Business Informatics, Vol. 1, 2014.
- [52] Van der Waerden, P.J.H.J.: "Pamela, a Parking Analysis Model for predicting Effects in Local Areas", doktorski rad, Technische Universiteit Eindhoven, 2012.
- [53] Kant, P.: "Route choice modelling in dynamic traffic assignment", magistarski rad, University of Twente, Centre for Transport Studies, 2008.
- [54] Zuurbier, F. S.: "Intelligent Route Guidance", doktorski rad, Delft University of Technology, Faculty of Civil Engineering and Geosciences, Department of Transport & Planning, 2010.
- [55] Sondak, R. C.: "Dynamic Intelligent Algorithm for Navigation (DIANA): A Route Finding System using Historical Traffic Data", magistarski rad, Delft University of Technology, Faculty of Electrical Engineering, Mathematics and Computer Science, Man-Machine Interaction Group, 2010.
- [56] Gudac, V., Anžek, M., Lanović, Z.: „Uputni garažno-parkirni sustav u gradu Rijeci“, *Korema, Automatizacija u prometu*, Congress Proceedings, Zadar, 2003., str. 26-27.
- [57] Lu, R., Lin, X., Zhu, H., Shen, X.: "SPARK: A New VANET-based Smart Parking Scheme for Large Parking Lots", *Proceedings of IEEE INFOCOM'07*, 2007.
- [58] Zhao, H., Lu, L., Song, C., Wu, Y.: "IPARK: Location-aware-based intelligent parking guidance over infrastructureless VANETs", *International Journal of Distributed Sensor Networks*, 2012.
- [59] Zhu, J., Liu, M., Wen, Y., Ma, C., Liu, B.: "Parking backbone: toward efficient overlay routing in VANETs", *International Journal of Distributed Sensor Networks*, 2014.
- [60] Hunt, J. D., Teply, S.: "A Nested Logit Model of Parking Location Choice", *Transportation Research B*, Vol. 27, 1993., str. 253-265.
- [61] Miller, E. J.: "Central Area Mode Choice and Parking Demand", *Transportation Research Record 1413*, 1993., str. 60-69.
- [62] Lambe, T. A.: "Driver Choice of Parking in the City", *Socio-Economic Planning Science*, Vol. 30, 1996., str. 207-219.
- [63] Hess, S., Polak, J. W.: "Mixed Logit Modeling of Parking Type Choice Behavior", *Transportation Statistics*, J. Ross Publishing Inc., USA, 2009., str. 77-102.
- [64] Guan, H., Xiaoduan Sun, P.E., Liu, X., Liu, L.: "Modeling Parking Behavior for Better Control and Pricing: A Case Study from One of the Busiest Retail Shopping Areas in Beijing, China", 84th Annual Meeting of the Transportation Research Board, Washington, USA, 2005.
- [65] Harmatuck, D. J.: "Revealed Parking Choices and the Value of Time", 86th Annual Meeting of the Transportation Research Board, Washington, USA, 2007.

- [66] Borgers, A., Kemperman, A., Toll, L., Timmermans, H.: "Measuring Preferences for Parking Facilities in Old Residential Areas", 7th International Symposium on City Planning and Environmental Management in Asian Countries, Fukuoka, Japan, 2010., str. 1-14.
- [67] Anžek, M., Kavran, Z., Uzelac, Z.: "Evaluation of parking m-payment in the Republic of Croatia", Proceedings of the European Congress and Exhibition on Intelligent Transport Systems and Services "Moving Towards an Integrated Europe", Budapest, 2004.
- [68] Brčić, D., Anžek, M., Krasić, D.: "Real-time Telematic Parking Guidance Systems", 12th International symposium on electronics in traffic, Ljubljana, 2004.
- [69] Pupavac, D., Maršanić, R.: "Basic propositions for optimization of the city parking capacity", Ekonomski pregled, Vol. 61 (7-8), 2010., str. 476-485.
- [70] Brčić, D., Kraljević, M.: "Uloga politike parkiranja u reguliranju prometa u gradovima", Drugi hrvatski kongres o cestama, 1999.
- [71] Brčić, D., Šoštarić, M.: "Parkiranje i garaže", Fakultet prometnih znanosti, Sveučilište u Zagrebu, Zagreb, 2012.
- [72] Maršanić, R.: "Kultura parkiranja: organizacija, tehnologija, ekonomika, ekologija, pravo", IQ plus, Rijeka, 2012.
- [73] Shoup, D. C.: "The high cost of free parking", American Planning Association, US, 2011.
- [74] De Dios Ortúzar, J., Willumsen, L. G.: "Modelling transport", John Wiley & Sons, UK, 2011.
- [75] Milosavljević, N.: "Parkiranje", Saobraćajni fakultet, Univerzitet u Beogradu, Beograd, 2010.
- [76] Jelinović, Z.: "Promet u mirovanju", Informator, Zagreb, 1973.
- [77] PROGRESS WP2: Scheme Design and Development, Pricing ROad use for Greater Responsibility, Efficiency and Sustainability in cities, Deliverable D3.2, V 2.0, 2002.
- [78] Topp, H. H.: "Parking policies to reduce car traffic in German cities", *Transport Reviews*, Vol. 13, No. 1, 1993., str. 83-95.
- [79] Cassidy, C.R., Kobza, J.E.: "A Probabilistic Approach to Evaluate Strategies for Selecting a Parking Space", *Transportation science*, Vol. 32, No. 1, 1998.
- [80] Burdette, D.: "An evaluation of advanced parking information systems at airports", Preprint, Transportation Research Board Annual Meeting, Washington D.C., 2001.
- [81] Griffith, E.: "Pointing the way", *ITS International*, March/April 2000., str. 72.
- [82] Cheung, S.Y., Ergen, S.C., Varaiya, P.: "Traffic surveillance with wireless magnetic sensors", Proceedings of the 12th ITS World Congress, November, 2005., San Francisco, str. 1-13.
- [83] Lenz, J.E., Edelstein, A.S.: "A review of magnetic sensors", *IEEE Sensors Journal*, 2006., str. 631-649.
- [84] Wolff, J., Heuer, J., Haibin, T., Weinmann, G., Voit, M., Hartmann, S.: "Parking monitor system based on magnetis field sensors", IEEE Intelligent Transportation System Conference, Toronto, 2006., str. 1275-1279.

- [85] Kastrinaki, V., Zervakis, M., Kalaitzakis, K.: "A survey of video processing techniques for traffic application", *Image vision Computing*, Vol. 21, 2003., str. 359-381.
- [86] Tang, V.W.S., Zheng, Y., Cao, J.N.: "An intelligent car park management system based on wireless sensor networks", 1st International Symposium on Pervasive Computing and Applications, Urumqi, 2006., str. 65-70.
- [87] Bi, Y.Z., Sun, L.M., Zhu, H.S., Yan, T.X., Luo, Z.J. : "A parking management system based on wireless sensor network", *Acta Automatica Sin.*, 32, 2006., str. 877-968.
- [88] Hampapur, A., Brown, L., Connell, J., Ekin, A., Haas, L. : "Smart video surveillance: Exploring the concept of multiscale spatiotemporal tracking", *IEEE Signal Process Magazine*, Vol. 22, 2005., str. 38-51.
- [89] Wu, Q., Huang, C.C., Wang, S.Y., Chiu, W.C., Chen, T.H.: "Robust parking space detection considering inter-space correlation", IEEE International Conference On Multimedia, Beijing, 2007., str. 659-662.
- [90] Funck, S., Mohler, N., Oertel, W.: "Determining car-park occupancy from single images", IEEE Intelligent Vehicles Symposium, Dresden, Germany, 2004., str. 325-328.
- [91] Bong, D.B.L., Ting, K.C., Rajae, N.: "Car-park occupancy information system", Third Real-Time Technology and Application Symposium, Serdang, Selangor, 2006.
- [92] Bong, D.B.L., Ting, K.C., Lai, K.C.: "Integrated approach in the design of car-park occupancy information system", *IAENG International Journal of Computing Science*, Vol. 35, 2008., str. 1-8.
- [93] Idna, M.Y., Noor, N.M., Razak, Z., Ridzuan, M.N.: "Parking system using chain code and A-star algorithm", International Conference on Intelligent Systems, Kuala Lumpur, Malaysia, 2005., str. 1-5.
- [94] Huang, C.C., Wang, S.J., Chang, Y.J., Chen, T.: "A bayesian hierarchical detection framework for parking space detection", IEEE International Conference on Acoustic, Signal and Image Processing, Las Vegas, NV., 2008., str. 2097-2100.
- [95] Caicedo, F.: "Real-time parking information management to reduce search time, vehicle displacement and emissions", *Transportation Research Part D*, Vol. 15, Elsevier, 2010., str. 228-234.
- [96] Axhausen, K.W., J.W. Polak: "A disaggregate model of the effects of parking guidance systems", In 7th WCTR Meeting Proceedings, Advanced Traveler Information Systems. Sydney, Australia, 1995.
- [97] Space control, *Highways*, April, 1998., str. 15.
- [98] Botltze, M., Dinter, M., Schottler, U.: "The project FRUIT: a goal-oriented approach to traffic management in Frankfurt am Main and the Rhine-Main Region", *Traffic Engineering + Control*, 1994., str. 437-444.
- [99] Van den Berghe, L.: "Guidance for Ghent. Parking directions over the cable TV network", *Traffic Technology International*, Annual Review, 1998., str. 58-62.
- [100] Orski, K.: "Best Space Scenario", *Traffic Technology International*, 2003.
- [101] Spencer, M., Brame, D.S., Hernandez, F.: "The development of an advanced parking information system plan", *Transportation Research Record*, Vol. 1886., 2004., str. 34-39.

- [102] Thompson, R.G., Bonsall, P.: "Drivers' response to parking guidance and information systems", *Transport Reviews*, Vol. 17, No. 2, 1997., str. 89-104.
- [103] Peng, W.: "Roles of Factors in Simulation of Parking Guidance and Information Systems", *Magistarski rad*, The University of New South Wales, Sydney, Australia, 2008.
- [104] Obdeijn, C.: "Modelling parking guidance systems in S-Paramics", *Magistarski rad*, Universiteit Twente, Enschede, Netherland, 2011.
- [105] Van der Waerden, P.: "Pamela, a Parking Analysis Model for predicting Effects in Local Areas", *Doktorski rad*, Technische Universiteit Eindhoven, Faculteit Bouwkunda, Urban Planning group, Eindhoven, Netherland, 2012.
- [106] Parma, K.: "Challenges and Guidelines for Implementing Advanced Parking Information Systems in the United States for Daily Downtown Traffic", Compendium of graduate students papers on advanced surface transportation systems, Department of Civil Engineering, Texas A & M University. College Station, TX, 1996.
- [107] Teng, H., Falcocchio, J.D., Patel, R., Ulerio, J.M., Afshar-Ghotli, A., Huang, A., Qi, Y.: "A feasibility study of a parking information system in NYC", Preprint, Transportation Research Board Annual Meeting, Washington, D.C., 2002.
- [108] Smith, L., Roth, H.: *Parking Systems Technology Report*, ITS Decision, Partners for Advanced Transit and Highways, University of California at Berkeley http://www.path.berkeley.edu/~leap/serv_and_tech/Parking_Systems_Technologies/parking_systems_tech_report.htm (12.7.2003.)
- [109] Mirnabela, L.Y., Klein, L.A.: "A summary of vehicle detection and surveillance technologies used in intelligent transportation systems", New Mexico State University, Tech. Report, 2007.
- [110] Mouskos, K.C., Boile, M., Parker, N.: "Technical solutions to overcrowded park and ride facilities", University Transportation Research Center-Region 2. City College of New York, Final Report, FHWA-NJ-2007-01.
- [111] Shaheen, S.: "Smart parking management field test: A bay area rapid transit (bart) district parking demonstration", *Institute of Transportation Studies*, 2005.
- [112] "Why Parking Matters?", International Parking Institute, 2014.
- [113] "2013 Emerging Trends in Parking", Report on a survey conducted by the International Parking Institute, International Parking Institute, 2014.
- [114] "Key messages from the parking sector", European Parking Association, 2014.
- [115] Klein, L. A., Kelley, M. R.: "Detection Technology for IVHS, Volume I: Final Report", Federal Highway Administration, U.S. Department of Transportation, 1996.
- [116] Sušan, J.: "Navigacijski radar", Sveučilište u Rijeci, Pomorski fakultet u Rijeci, 2006.
- [117] Dudek, C. L., Ullman, G. L.: "Dynamic Message Sign Message Design And Display Manual", Texas Transportation Institute, 2006.
- [118] Nygårdhs, S.: "Literature review on variable message signs (VMS) 2006–2009", Swedish National Road and Transport Research Institute, 2011.

- [119] Dahiya, A., Chauhan, R. K.: "A Comparative study of MANET and VANET Environment", *Journal of Computing*, Vol. 2 (7), 2010.
- [120] Kim, T. H., Hong, W. K., Kim, H.: "An effective multihop broadcast in vehicular adhoc networks", proceedings 20th International Conference on Architecture of Computing Systems, ARCS 2007, Springer, 2007.
- [121] CAR 2 CAR Communication Consortium: "Overview of the C2C-CC System", izvješće, 2007.
- [122] Uhlemann, E.: "Introducing Connected Vehicles", *IEEE vehicular technology magazine*, Vol. 10 (1), 2015., str. 24.
- [123] ICSI consortium: Deliverable D1.3.2. System Architecture, 2015.
- [124] Schofer, J. L., Koppelman, F. S., Charlton, W. A.: "Perspectives on Driver Preferences for Dynamic Route Guidance Systems", *Transportation Research Record*, Vol. 1588, 1997, str. 26.
- [125] Henn, V.: "Fuzzy route choice model for traffic assignment", *Fuzzy Sets and Systems*, Vol. 116 (11), 2000., str. 77-101.
- [126] Rilett, L.R., Park, D.: "Incorporating uncertainty and multiple objectives in real-time route selection", *Journal of Transportation Engineering*, Vol. 127 (6), 2001., str. 531-539.
- [127] Ridwan, M.: "Fuzzy preference based traffic assignment problem", *Transportation Research Part C*, Vol. 12 (3-4), 2004., str. 209-233.
- [128] Yamamoto, T., Kitamura, R., Fujii, J.: "Drivers' route choice behavior: analysis by data mining algorithms", *Transportation Research Record*, Vol. 1807, 2002., str. 59-66.
- [129] Nakayama, S., Kitamura, R., "Route choice model with inductive learning", *Transportation Research Record*, Vol. 1725, 2000., str. 63-70.
- [130] Nakayama, S., Kitamura, R., Fujii, S., "Drivers' route choice rules and network behavior: do drivers become rational and homogeneous through learning?", *Transportation Research Record*, Vol. 1752, 2001., str. 62-68.
- [131] Dijkstra E. W.: "Note on Two Problems in Connection with Graphs", *Numerical Mathematics*, Vol. 1, 1959., str. 269-271.
- [132] Wardrop, J. G., Whitehead, J. I.: "Correspondence. Some Theoretical Aspects of Road Traffic Research", ICE Proceedings: Engineering Divisions, Vol. 1 (5), 1952.
- [133] Bureau of Public Roads: "Traffic Assignment Manual", U.S. Dept. of Commerce, Urban Planning Division, Washington D.C., 1964.
- [134] Frank, M., Wolfe, P.: "An algorithm for quadratic programming", *Naval Research Logistics Quarterly*, Volume 3 (1-2), 1956., str. 95-110.
- [135] Ramming, M. S.: "Network Knowledge and Route Choice", doktorski rad, Massachusetts Institute of Technology, 2002., str. 33.
- [136] Almond, J.: "Traffic Assignment with Flow-Dependent Journey Times", *Vehicular Traffic Science*, Proceedings from the 3rd International Symposium on the Theory of Traffic Flow, American Elsevier, New York, 1967.

- [137] Dial, R. B.: "A Probabilistic Multipath Traffic Assignment Algorithm which Obviates Path Enumeration", *Transportation Research*, Vol. 5 (2), 1971., str. 83-111.
- [138] Fisk, C. S.: "Some Developments in Equilibrium Traffic Assignment", *Transportation Research B*, Vol. 14 (3), 1980., str. 243-255.
- [139] Chen, M., Alfa, A. S.: "Algorithms for Solving Fisk's Stochastic Traffic Assignment Model", *Transportation Research B*, Vol. 25 (6), 1991., str. 405-412.
- [140] Ben-Akiva, M. E., Bergman, M. J., Daly, A. J., Ramaswamy, R.: "Modelling Inter Urban Route Choice Behavior", Ninth International Symposium on Transportation and Traffic Theory, VNU Science Press, 1984., str. 299-330.
- [141] Ben-Akiva, M. E., Lerman, S. R.: "Discrete Choice Analysis: Theory and Application to Travel Demand", MIT Press, Cambridge, MA, 1985.
- [142] De La Barra, T., Perez, B., Anez, J.: "Multidimensional Path Search and Assignment", Proceedings of the 21st PTRC Summer Meeting, 1993., str. 307-319.
- [143] Park, D., Rilett, L. R.: "Identifying Multiple and Reasonable Paths in Transportation Networks: A Heuristic Approach", *Transportation Research Record* 1607, 1997., str. 31-37.
- [144] Bellman, R., Kalaba, R.: "On k^{th} Best Policies", *Journal of the Society for Industrial and Applied Mathematics*, Vol. 8 (4), 1960., str. 582-588.
- [145] Sheffi, Y., Powell, W. B.: "An Algorithm for the Equilibrium Assignment Problem with Random Link Times", *Networks*, Vol. 12 (2), 1982., str. 191-207.
- [146] Cascetta, E., Nuzzolo, A., Russo, F., Vitetta, A.: "A Modified Logit Route Choice Model Overcoming Path Overlapping Problems: Specification and Some Calibration Results for Interurban Networks", *Transportation and Traffic Theory*, Proceedings of the 13th International Symposium on Transportation and Traffic Theory, France, 1996., str. 697-711.
- [147] Ben-Akiva, M. E., Ramming, M. S.: "Lecture Notes: Discrete Choice Models of Traveler Behavior in Networks", Prepared for Advanced Methods for Planning and Management of Transportation Networks, Italy, 1998.
- [148] Vovsha, P., Bekhor, S.: "The Link-Nested Logit Model of Route Choice: Overcoming the Route Overlapping Problem", *Transportation Research Record* 1645, 1998., str. 133-142.
- [149] Yai, T., Iwakura, S., Morichi, S.: "Multinomial Probit with Structured Covariance for Route Choice Behavior", *Transportation Research B*, Vol. 31(3), 1997., str. 195-207.
- [150] Cascetta, E., Papola, A., Russo, F., Vitetta, A.: "Implicit Availability/Perception Logit Models for Route Choice in Transportation Networks", *World Transport Research: Selected Proceedings of the 8th World Conference on Transport Research*, Belgija, 1999., str. 15-24.
- [151] Tversky, A.: "Elimination by Aspects: A Theory of Choice", *Psychological Review*, Vol. 79, 1972., str. 281-299.
- [152] Ben-Akiva, M. E., Boccara, B.: "Discrete Choice Models with Latent Choice Sets", *International Journal of Research in Marketing*, Vol. 12 (1), 1995., str. 9-24.

- [153] Wiedemann, R.: "Simulation des Straßenverkehrsflusses", Schriftenreihe des Instituts für Verkehrswesen der Universität Karlsruhe, 1974.
- [154] Wiedemann, R.: "Modelling of RTI-elements on multi-lane roads", *Advanced Telematics in Road Transport*, Proceedings of the DRIVE Conference, Vol. 2, New York, Elsevier, 1991., str. 1007-1019.
- [155] Planung Transport Verkehr AG: PTV VISSIM 6 User Manual, Karlsruhe, Njemačka, 2014.
- [156] Ligterink, N., Kadijk, G., Mensch, P., Hausberger, S., Rexeis, M.: "Investigations and real world emission performance of Euro 6 light-duty vehicles", TNO report, TNO 2013 R11891, 2013.
- [157] Environmental Protection Agency: "U.S Transportation Sector Greenhouse Gas Emissions 1990-2011", Office of Transportation and Air Quality, EPA420-F-05-004, 2005.
- [158] Liu, Y.: "A model system to evaluate the impacts of vehicle-related taxation policies on household greenhouse gas emissions", *magistarski rad*, Faculty of the Graduate School of the University of Maryland, 2014.
- [159] Senna, H. A., Radwan, E., Westerlund, K., Cooper, C. D.: "Using a traffic simulation model (VISSIM) with an emissions model (MOVES) to predict emissions from vehicles on a limited-access highway", *Journal of the Air & Waste Management Association*, Vol. 63 (7), 2013., str. 819-831.
- [160] Mathew, T. V., Rao, K. K.: "Introduction to Transportation engineering", *Civil Engineering-Transportation Engineering*, IIT Bombay, NPTEL ONLINE, 2015. <http://www.nptel.ac.in/courses/105101087/39> (2.2.2015.)
- [161] Highway Capacity Manual - HCM2010, Transportation Research Board of the National Academies, 2010.

Životopis

Rođen sam 4. kolovoza 1972. godine u Zagrebu. Od druge godine života živim u Rijeci gdje sam završio osnovnu i srednju elektrotehničku školu. Na Pomorskom fakultetu u Rijeci, 1996. stekao sam zvanje inženjer pomorskog prometa smjera pomorskih komunikacija i brodske elektronike. Razlikovnu godinu upisao sam 2007. godine i stekao zvanje sveučilišni prvostupnik (baccalareus) inženjer elektroničke i informatičke tehnologije. Godine 2008., također na Pomorskom fakultetu upisujem diplomski studij na smjeru elektroničke i informatičke tehnologije u pomorstvu. Diplomirao sam 2011. godine, te stekao visoku stručnu spremu i stručni naziv magistar inženjer elektroničke i informatičke tehnologije.

Tijekom studija bio sam demonstrator iz četiri kolegija vezanih uz elektroniku i informatiku te demonstrator u biblioteci Fakulteta. U isto vrijeme održavam tečajeve informatike za informatičke škole i IT poduzeća, a s profesionalnom se elektronikom upoznajem radeći preko student servisa u poduzeću ADRIA-electronic d.o.o. iz Rijeke.

Od 1996. godine zaposlen sam u poduzeću *Digital point* d.o.o. Rijeka koji me upošljava na osnovi preporuke voditelja biblioteke Fakulteta gdje prije svega usavršavam svoje znanje na području grafike. Grafikom i grafičkim djelatnostima intenzivno se bavim cijeli niz godina prolazeći kroz različita radna mjesta u poduzeću i upoznavajući sve aspekte poslovanja.

U trenutku kada se poduzeće počinje intenzivnije baviti razvojem specifičnih programskih aplikacija postajem voditelj programerskog tima i odjela razvoja koji kao rezultat višegodišnjeg rada stvara prvi programski paket u RH nagrađen priznanjem „Zlatna kuna“ za kvalitetu, a poduzeće dobiva certifikat ISO 9001. Od ostalih se sklopovsko-programskih rješenja nastalih u tom vremenu posebno izdvajaju sustav za satelitsko lociranje i praćenje vozila *SatLoc* te sustav za administraciju vatrogasnih intervencija *Vatra*.

Posljednjih sedam godina koje provodim u poduzeću *Digital point* i poduzećima koja su dio grupacije radim na poslovima voditelja komercijale i savjetnika, te naposljetku djelujem u svojstvu menadžera i partnera.

Pored svega navedenog prošao sam i dodatna usavršavanja, postajem Microsoft Certified Professional, te stječem svjedodžbe o osposobljenosti iz područja rada s različitim operativnim sustavima (različite inačice MS Windowsa, Unix i Macintosh

OS-a) i programskim paketima (Adobe, QuarkXPress, CorelDraw i sl.). Aktivno se služim i cijelim nizom raznih drugih računalnih aplikacija poput NI Multisim, NI LabVIEW, Matlab i Simulink.

U prosincu 2010. zapošljam se na Pomorskom fakultetu u Rijeci prvo kao djelatnik informatičkog centra gdje provodim dvije godine, a zatim kao asistent na Zavodu za elektrotehniku, informatiku i automatiku gdje sudjelujem u nastavi iz kolegija Održavanje elektroničkih sustava, Mikro i osobna računala i Inteligentni transportni sustavi.

Trenutno aktivno surađujem u svojstvu istraživača na dvama projektima: projekt Ministarstva znanosti, obrazovanja i sporta pod nazivom 'Informacijsko-komunikacijske tehnologije u inteligentnim pomorskim sustavima' (112-1121722-3314, voditelj prof. dr. sc. Vinka Tomasa) koji se od 2014. godine nastavlja pod nazivom 'Informacijsko-komunikacijske tehnologije u inteligentnim prometnim sustavima' (potpora UniRi) i na projektu 'Intelligent Cooperative Sensing for Improved Traffic Efficiency' (FP7-317671, 2012-2015, voditelj prof. dr. sc. Sadko Mandžuka, Fakultet prometnih znanosti Sveučilišta u Zagrebu).

U akademskoj godini 2011/12. upisujem na Pomorskom fakultetu u Rijeci poslijediplomski doktorski studij 'Pomorstvo', modul: Elektronika i pomorske komunikacije (2. godina, prosjek ocjena: 5.0). Većinu istraživanja provedenih u sklopu dokorskog studija čine tematske cjeline iz područja inteligentnih transportnih sustava.

Samostalno i u koautorstvu do sada sam objavio dvije knjige i 8 znanstvenih i stručnih radova, od čega tri u časopisima i pet u zbornicima međunarodnih i domaćih konferencija.

Član sam hrvatskih društava MIPRO, ELMAR i ITS Croatia, međunarodnog društva IEEE, te povjerenik Hrvatske udruge programera za Primorsko-goransku županiju i jedan od voditelja Microsoft Community SQL/DEV grupe korisnika.